

**DISEÑO DE UNA METODOLOGÍA PARA EL MAPEO DE LA
CONCENTRACIÓN DE MANGLAR EN LA BAHÍA DEL DISTRITO DE
BUENAVENTURA DEL VALLE DEL CAUCA A PARTIR DE IMÁGENES
SATELITALES**

OMAR ELICEO TORRES OBREGÓN



**Universidad
del Valle**

**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA CIVIL Y GEOMÁTICA
SANTIAGO DE CALI, COLOMBIA
MARZO, 2022**

**DISEÑO DE UNA METODOLOGÍA PARA EL MAPEO DE LA
CONCENTRACIÓN DE MANGLAR EN LA BAHÍA DEL DISTRITO DE
BUENAVENTURA DEL VALLE DEL CAUCA A PARTIR DE IMÁGENES
SATELITALES**

OMAR ELICEO TORRES OBREGÓN

TRABAJO DE GRADO

**DIRECTOR:
CÉSAR EDWIN GARCÍA CORTES
INGENIERO TOPOGRÁFICO**



**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA CIVIL Y GEOMÁTICA
PROGRAMA DE INGENIERÍA TOPOGRÁFICA
MARZO, 2022**

NOTA DE ACEPTACIÓN

Firma Presidente del Jurado
Director

Firma Jurado 1

Firma Jurado 2

Santiago de Cali, _____

AGRADECIMIENTOS

Quiero expresar profundo agradecimiento primeramente a Dios por concederme la gran oportunidad de cumplir con mis metas y propósito como lo es concluir a feliz término mi proyecto académico universitario, a mi familia y amigos por su apoyo incondicional.

*Un agradecimiento muy especial al profesor **Ing. César Edwin García Cortés** director de mi tesis por su orientación, acompañamiento, comprensión y colaboración, además de su calidad humana, lo cual ha sido totalmente significativa para el éxito de este proyecto. Así mismo, quiero agradecer a la profesora Ing. Jackeline Murillo Hoyos por su valioso apoyo y colaboración, a los demás profesores y compañeros del programa académico de Ingeniería Topográfica que han estado presente en contribuir a la consolidación de este propósito.*

A los jurados evaluadores, el ingeniero Franklin Arles Bedoya y José Eduardo Fuentes por el tiempo dedicado, las respectivas observaciones y correcciones al documento final de esta tesis.

Y finalmente pero no menos importante, quiero agradecer a la Universidad del Valle, alma máter, por su proyecto de inclusión y reivindicación a través de los programas académicos que ha permitido los aprendizajes y enseñanzas que ponderan el conocimiento y la motivación a la inquietud persistente y aplicada.

TABLA DE CONTENIDO

1. INTRODUCCIÓN.....	10
2. PLANTEAMIENTO DEL PROBLEMA.....	11
3. OBJETIVOS	13
3.1 Objetivo General.....	13
3.2 Objetivos Específicos.....	13
4. JUSTIFICACIÓN.....	14
5. MARCO TEÓRICO	15
5.1. Marco Conceptual	15
5.1.1. Manglares.....	15
5.1.2. Percepción Remota	16
5.1.2.1 Sensores Analizados.....	16
5.1.2.2 Correcciones a imágenes de satélite.....	18
5.1.2.3 Optimun Index Factor (OIF)	19
5.1.2.3.1 Combinación sin repeticiones.....	20
5.1.3. Índices de Vegetación	20
5.1.4. Clasificación Supervisada.....	22
5.1.4.1. Algoritmos del SCP	22
5.1.4.2. Matriz de Confusión.....	24
5.1.5. Quantum GIS (QGIS)	25
5.2. Marco Referencial	26
6. MATERIALES Y ÁREA DE ESTUDIO	31
6.1. Reconocimiento y delimitación de la zona de estudio.....	31
6.2. Búsqueda, descarga y adquisición de material.	32
7. METODOLOGÍA.....	34
7.1. Fase 1: Preprocesamiento de las imágenes satelitales	34
7.2. Fase 2: Cálculo de índices espectrales	35
7.3. Fase 3: Evaluación de métodos de clasificación para identificación de manglares	36
7.4. Fase 4: Postprocesamiento de las imágenes.....	36

7.5. Fase 5: Construcción de polígonos con concentración de manglar.....	36
8. RESULTADOS	37
8.1 Índices espectrales que contribuyen en la identificación de manglar en la bahía de Buenaventura.....	37
8.2 Clasificación de las imágenes de satélite para el reconocimiento de zonas de manglares.....	44
8.3 Áreas con concentración de manglares, validación por matriz de confusión	49
9. CONCLUSIONES	55
10. RECOMENDACIONES	57
11. REFERENCIAS BIBLIOGRÁFICAS	58

ÍNDICE DE FIGURAS

Figura 1: Zona de Estudio: Bahía de Buenaventura.....	32
Figura 2: Flujograma Metodología.....	34
Figura 3: Imagen 5 TM; Imagen 7 ETM.....	37
Figura 4: Aplicación de parche en las imágenes Landsat de la zona de estudio.....	37
Figura 5: Índice de vegetación normalizada.....	40
Figura 6: Índice de vegetación ajustado al suelo.....	40
Figura 7: Índice diferencial de agua normalizado.....	41
Figura 8: Índice modificado de agua diferencial normalizado.....	42
Figura 9: Índice de vegetación de manglar.....	42
Figura 10: (a) Combinación 451, (b) Combinación 145, (c) Combinación 514, (d) Combinación 415, (e) Combinación 541 y (f) Combinación 154.....	43
Figura 11: Imagen clasificada usando el MVI.....	44
Figura 12: Gráfico de firma espectral.....	44
Figura 13: Imagen filtrada.....	45
Figura 14: Áreas de entrenamiento.. ..	45
Figura 15: Imagen clasificada, algoritmo mínima distancia.....	46

Figura 16: Imagen clasificada y mejorada, mínima distancia.....	47
Figura 17: Imagen clasificada, algoritmo máxima probabilidad.....	47
Figura 18: Imagen clasificada y mejorada, máxima probabilidad.....	48
Figura 19: Imagen clasificada, algoritmo mapeo de ángulo espectral.....	48
Figura 20: Imagen clasificada y mejorada, mapeo de ángulo espectral.....	49
Figura 21: Polígonos de manglar, mínima distancia.....	50
Figura 22: Polígonos de manglar, máxima probabilidad.....	50
Figura 23: Polígonos de manglar, mapeo de ángulo espectral.....	51
Figura 24: Precisión total clasificación.....	54
Figura 25: Concordancia clasificación.....	55

ÍNDICE DE TABLAS

Tabla 1. Análisis multitemporal de manglares en el sector isla de Leoncico.....	11
Tabla 2. Longitudes de onda y resolución de las bandas, Landsat 5 TM.....	16
Tabla 3. Longitudes de onda y resolución de las bandas, Landsat 7 ETM+.....	17
Tabla 4: Esquema general de la matriz de confusión.....	24
Tabla 5. Escala de valoración índice de Kappa.....	25
Tabla 6. Comparativo áreas de manglar generadas por la CVC, 2012 vs 2001.....	27
Tabla 7. Parámetros de las imágenes utilizadas.....	33
Tabla 8. Características sensor TM y ETM.....	33
Tabla 9: Datos estadísticos de la imagen.....	38
Tabla 10: Matriz de coeficientes de correlación.....	39
Tabla 11. Valores del OIF.....	39
Tabla 12. Evaluación de la exactitud polígonos, mínima distancia.....	51
Tabla 13. Evaluación de la exactitud polígonos, máxima probabilidad	52
Tabla 14. Evaluación de la exactitud polígonos, mapeo ángulo espectral	53

RESUMEN

Identificar la concentración de manglar es de gran importancia en la caracterización y zonificación de los ecosistemas de manglar para controlar y mitigar la pérdida de este recurso natural, además, métodos convencionales como el Corin Land Cover liderado por el IDEAM, el cual se ha utilizado para el levantamiento de coberturas de suelo para esta zona de estudio han sido dispendiosos y lentos. Por consiguiente, es necesario diseñar e implementar un nuevo proceso metodológico ágil, robusto y eficiente que permita obtener información de la cobertura de manglares a lo largo de la costa y margen de los ríos desde imágenes de satélite Landsat para generar resultados válidos para la toma de decisiones.

En este sentido, se diseñó e implementó este nuevo método para mapear la concentración de manglar en la bahía de Buenaventura del Valle del Cauca detectada en las imágenes de satélite que consistió en procesar la información a través del plugin Semi-Automatic Classification (SCP) instalado en el software de acceso libre QGIS 3.20, en el que se calculó índices espectrales para la identificación de las características y áreas de la cobertura de manglar obtenidas con la aplicación de los algoritmos de clasificación de distancia mínima, máxima probabilidad y mapeo del ángulo espectral permitiendo obtener áreas de 1569.06 has, 1905.030 has y 1608.48 hectáreas respectivamente, mostrando que son propicios para distinguir los bosques de manglar. Para la validación de los productos fue necesario calcular la exactitud de los resultados mediante la matriz de confusión y el índice estadístico kappa tomando como referencia el mapa de manglares de la bahía de Buenaventura realizada por García (2012) cuya metodología fue implementada a partir de imágenes Landsat 5 del año 2011.

Aunque la zona de estudio presenta dificultades para trabajar con información generada por sensores pasivos por su alto grado de nubosidad, el desarrollo de esta propuesta permitió demostrar que esta nueva metodología para mapear la concentración de manglar es eficiente, manejable y precisa para obtener información de la cobertura de manglar a partir de la potencialidad del plugin Semi-Automatic Classification (SCP). Los resultados de 95.57% de precisión total y 0.6023 de grado de concordancia muestran que la clasificación realizada por el algoritmo de máxima probabilidad es mejor que la realizada por el algoritmo de distancia mínima cuyo valor de precisión es 95.42% y 0.564 de concordancia, y el de mapeo de ángulo espectral con valor de precisión es 95.5% y 0.5686 de concordancia.

PALABRAS CLAVES

Imagen satelital, bosques de manglar, complemento de clasificación semiautomática (SCP), índices espectrales, sensores remotos, QGIS.

ABSTRACT

Identifying the concentration of mangroves is of great importance in the characterization and zoning of mangrove ecosystems to control and mitigate the loss of this natural resource, in addition, conventional methods such as the Corin Land Cover led by IDEAM, which has been used to Land cover surveys for this study area have been costly and slow. Therefore, it is necessary to design and implement a new agile, robust and efficient methodological process that allows obtaining information on the coverage of mangroves along the coast and river banks from Landsat satellite images to generate valid results for taking data. decisions.

In this sense, this new method was designed and implemented to map the concentration of mangroves in the Buenaventura Bay of Valle del Cauca detected in the satellite images, which consisted of processing the information through the installed Semi-Automatic Classification (SCP) plugin. in the free access software QGIS 3.20, in which spectral indices were calculated for the identification of the characteristics and areas of mangrove coverage obtained with the application of the classification algorithms of minimum distance, maximum probability and mapping of the spectral angle allowing obtain areas of 1,569.06 hectares, 1,905,030 hectares, and 1,608.48 hectares, respectively, showing that they are conducive to distinguishing mangrove forests. For the validation of the products, it was necessary to calculate the accuracy of the results through the confusion matrix and the statistical kappa index, taking as a reference the map of mangroves of the Buenaventura Bay carried out by García (2012), whose methodology was implemented from images. Landsat 5 of the year 2011.

Although the study area presents difficulties in working with information generated by passive sensors due to its high degree of cloud cover, the development of this proposal made it possible to demonstrate that this new methodology for mapping the concentration of mangroves is efficient, manageable and accurate for obtaining information on the mangrove cover from the potential of the Semi-Automatic Classification (SCP) plugin. The results of 95.57% total accuracy and 0.6023 degree of agreement show that the classification made by the maximum probability algorithm is better than that made by the minimum distance algorithm whose accuracy value is 95.42% and 0.564 of agreement, and the of spectral angle mapping with precision value is 95.5% and 0.5686 of agreement.

KEY WORDS

Satellite image, mangrove forests, semi-automatic classification plugin (SCP), spectral indices, remote sensing, QGIS.

1. INTRODUCCIÓN

Los manglares proporcionan diversos servicios ecosistémicos ecológicos y económicos que contribuyen a la protección contra la erosión costera, la filtración de agua, la provisión de áreas para la cría de peces y camarones, la provisión de material de construcción e ingredientes medicinales y la atracción de turistas, entre muchos factores (Kuenzer et al., 2011). Para precisar en un contexto local, según INVEMAR (2007), se ha identificado que, en el litoral pacífico, la explotación de los recursos forestales de forma excesiva ha provocado claramente afectación en la estructura boscosa, impactando negativamente la diversidad de recursos biológicos que habitan en la fuente hídrica.

De acuerdo con la Unidad de Planeación Minero Energética UPME (2018), los manglares en la bahía de Buenaventura están en riesgo de tener una gran afección por la infraestructura portuaria para la operación del terminal, por tanto, dicha ocupación y la tala de manglar requiere de la modificación en la zonificación de manglar la cual fue aprobada mediante resolución del Ministerio del Ambiente y Desarrollo Sostenible.

Con el objetivo de identificar la concentración de manglar en la Bahía de Buenaventura, Valle del Cauca, se diseñó e implementó una metodología a partir de percepción remota utilizando imágenes de satélite del año 2011, cuyo procesamiento de las imágenes permite cartografiar la cobertura de mangle mediante la evaluación de índices de vegetación basados en el comportamiento variado de la energía y la respuesta espectral de atributos que cubren los suelos, como bien lo señala Rodríguez et al., (2018), además de la clasificación supervisada para identificar el contenido de la imágenes conforme a las firmas espectrales, esta metodología utiliza el complemento Semi-Automatic Classification (SCP) instalado en el software de acceso libre QGIS 3.20 utilizando los algoritmos de clasificación, de máxima probabilidad, mapeo de ángulo espectral y distancia mínima. Luego con el producto obtenido se validará mediante una matriz de confusión y el índice estadístico Kappa teniendo como referente una cartografía existente del año 2012, que presenta información fidedigna y con precisión de coberturas de manglar perteneciente al ente corporativo regional CVC, la cual ha sido de posible acceso en tiempos de aislamiento preventivo por asuntos de salud pública.

2. PLANTEAMIENTO DEL PROBLEMA

Según la FAO (2007), los manglares son bosques perennes tolerantes a la sal que crean ecosistemas de interfaz entre tierra y mar. Se encuentran en las zonas intermareales de los ecosistemas marinos, costeros y de estuarios de 124 países y áreas tropicales y subtropicales. Agregando a lo anterior, (Heenkenda et al, 2014) plantean que los manglares son un hábitat importante para el mantenimiento de la biodiversidad y también proporcionan beneficios directos e indirectos a las actividades humanas.

En la zona costera del pacífico colombiano, el uso y la explotación indiscriminada de bosques ha generado efectos determinados en la pérdida de componentes de ecosistemas de árboles y/o vegetación, incidiendo en la sucesión natural y reduciendo la diversidad de organismos que habitan en el ambiente hídrico, tales como la piangua en algunos sectores (CVC, 2007). Además, lo revalida (García, 2012) ilustrando que en las cuencas hidrográficas de la costa pacífica del Valle del Cauca hubo una pérdida de bosques de manglar equivalente a 130,8 hectáreas entre los años 2001 y 2011.

Aquí es importante subrayar que en el año 1995 se emitió la resolución 1602, la cual estableció que las Corporaciones Autónomas Regionales están obligadas a presentar ante el Ministerio de Ambiente, estudios sobre el estado de los manglares en el territorio de su jurisdicción incluyendo propuestas para su zonificación por consiguiente, en el año 2002 dicho Ministerio aprobó mediante Resolución No. 0721 del mes de julio el estudio denominado "Zonificación, caracterización y ordenación de los manglares Vallecaucanos" presentado por la Corporación Autónoma Regional de Valle del Cauca - CVC, estableciendo la zonificación de los bosques de manglar del departamento del Valle del Cauca con un área en hectáreas de 32073. Además, para el año 2017, se emite la resolución 0706 para la actualización de la zonificación de los manglares ubicados en el sector isla de Leoncico en jurisdicción del establecimiento público ambiental de Buenaventura, siendo así, es determinante la conveniencia de este proyecto, puesto que dicha extensión está contenida en la Bahía de Buenaventura, y ha presentado ciertas variaciones entre los años 1998 y 2016 (tabla 1).

Tabla 1. Análisis multitemporal de manglares en el sector isla de Leoncico

Cobertura		Unidad	Cantidad Año 1998	Cantidad Año 2006	Cantidad Año 2016
Manglar alto	denso	Has	58,74	91,11	74,88
Manglar alto	abierto	Has	47,87	26,03	42,08
Total		Has	106,61	117,14	116,96

Fuente: Ministerio de Ambiente, Resolución 0706 de 2017

Por otra parte, García (2012), determinó que el área de manglar en el departamento del Valle del Cauca es de 31942.22 has, cuya distribución están dadas por las áreas de 673.7 has para la cuenca del río Bajo San Juan, 4549.9 has en la cuenca de Bahía Málaga, 1984.5 has para la cuenca Bahía de Buenaventura, 1314.4 has en la cuenca del río Dagua, 6200.6 has para la cuenca del río Anchicayá, 4504.7 has en la cuenca del río Raposo, 991.7 has contenido en la cuenca del río Mallorquín, 5217 has en la cuenca del río Cajambre, 3763 has corresponde a cuenca del río Yurumangui y 2742.8 has en la cuenca del río Naya.

Ahora bien, la Corporación Autónoma Regional del Valle del Cauca (2020), en su plan de acción 2020 – 2023 cuyo propósito principal es acercar la autoridad ambiental a los vallecaucanos, además de todo lo que configura su hoja de ruta para el cumplimiento de metas y objetivos durante el respectivo periodo, determinó dentro de las acciones operativas, el proyecto de caracterización de la biodiversidad y sus servicios ecosistémicos, además de la formulación de alternativas para su conservación; este tiene como producto la zonificación y régimen de usos para el ecosistema manglar ajustado, por tanto, se proyectó como meta el 100% de manglares en proceso de ajuste para el año 2021, esto conlleva a que se pueda dar manejo de las áreas de manglar en la zona definida a partir de divisiones espaciales del territorio conforme con principios de agrupamiento y así establecer los usos y sus consecuentes actividades permitidas.

Teniendo en cuenta lo anterior, la finalidad de este proyecto de investigación se centra en aplicar una metodología basada en la percepción remota utilizando índices de vegetación y clasificación supervisada de mínima distancia, mapeo de ángulo espectral y máxima probabilidad mediante el plugin Semi-Auto classification SCP para QGIS. Vale la pena señalar, que en el mapeo de la concentración de manglar se destaca el algoritmo máxima probabilidad, ya que es perfecto en distinguir los manglares y clases de manglares de ambos niveles de clases y macroclases. (Purwanto & Riyanto, 2020), además es el más común, aunque en el proceso de clasificación puede ser más lento que el algoritmo de distancia mínima (Congedo, 2021).

Como señala Chuvieco (2008), en el análisis de ecosistemas de manglares con imágenes de satélites, se presentan mayores atributos sobresalientes en el rango del espectro visible e infrarrojo, en el marco de esta investigación se ha planteado el siguiente interrogante:

¿Qué resultados puede generar la implementación de esta metodología de percepción remota basada en índices de vegetación y algoritmos de clasificación supervisada mediante el Semi-Auto Classification Plugin (SCP) en el mapeo de la concentración de manglar de la bahía de Buenaventura en el Valle del Cauca?,

agregado a lo anterior, ¿Qué características espectrales presentaron la vegetación de manglar en la zona de estudio para el año 2011?

3. OBJETIVOS

3.1 Objetivo General

Diseñar una metodología para el mapeo de la concentración de manglar en la bahía del Distrito de Buenaventura utilizando imágenes de satélite (Landsat).

3.2 Objetivos Específicos

- ✓ Valorar diferentes índices espectrales que contribuyan en la identificación de manglar de la bahía de Buenaventura.
- ✓ Evaluar la potencialidad de los métodos de clasificación para imágenes de satélite que permitan el reconocimiento de zonas de manglares.
- ✓ Identificar las áreas con mayor concentración de manglares.

4. JUSTIFICACIÓN

Los sensores de satélites espaciales convencionales han desempeñado un papel importante en la cartografía de los manglares en grandes regiones geográficas, y los sensores utilizados, el número de diferentes metodologías aplicadas, los datos más utilizados provienen de Landsat-5 TM y SPOT. Además, algunos investigadores utilizaron datos de Landsat MSS, Landsat-7 ETM +, el satélite de detección remota de la India (IRS) 1C / 1D LISS III y el radiómetro de reflexión y emisión térmica espacial avanzado (ASTER) Kuenzer et al., (2011). Desde otra perspectiva, Rodríguez et al., (2019), menciona que las imágenes satelitales RapidEye, SPOT 5, Landsat 8 y SPOT 6 son apropiadas para el estudio de bosques de manglar, fundamentando su concepto en las resoluciones espacial y espectral.

De acuerdo con Hernández (2020), el acceso a la información de sensores remotos junto con información procedente de los inventarios forestales evalúa variables de interés con precisión y bajo coste, permitiendo la toma de decisiones a situaciones que puede afectar los ecosistemas.

Es necesario señalar que a nivel mundial la convención sobre los humedales de importancia internacional RAMSAR (2010), dentro de las prioridades de los futuros inventarios de hábitats de humedales, los cuales carecen de información o que corren peligro de disminución y pérdida están los manglares, puesto que la cartografía de estos humedales es mejor que la de otros humedales costeros y marinos, sin embargo, presentan ciertas contradicciones lo que incide en la falta de un inventario más exhaustivo.

Ciertamente, el cuidado y manejo de los recursos marinos, teniendo en cuenta su agotamiento es una preocupación no sólo de las autoridades ambientales y públicas administrativas sino también de la humanidad, por consiguiente, es de gran importancia monitorear y controlar la explotación excesiva de los ecosistemas de manglar en la región de estudio, puesto que desde tiempos remotos, muchos habitantes de la zona costera están vinculados a las prácticas de supervivencia relacionadas a la explotación maderera, la extracción de moluscos y de peces, entre otros.

Lo más importante, es que los resultados a obtener a partir de la puesta en marcha de este proyecto usando herramientas tecnológicas de teledetección y sistemas de información geográfica SIG, aportan a la solución de problemas para trabajar con diferentes sensores, diferentes resoluciones y diferentes fechas proporcionando información de las coberturas superficiales, especialmente la de bosques de manglar de la Bahía de Buenaventura en el Valle del Cauca. Y estos resultados, son comparados mediante una matriz de confusión con los resultados obtenidos con la metodología desarrollada por García, (2012) para la generación de cartografía temática de cobertura de manglar con imágenes Landsat del año 2011.

5. MARCO TEÓRICO

5.1. Marco Conceptual

Los estudios que se han podido realizar esencialmente, los referentes a los manglares desde las acciones que conducen al aprovechamiento de este recurso natural han sido soportados en diferentes referentes teóricos y conceptuales que propenden en dar explicación del conocimiento teórico sobre el entendimiento de la capacidad de analizar la variación de manglares como proceso que afecta los ecosistemas, centrado en el reconocimiento de que el cuidado y protección de los manglares trasciende en su uso y explotación.

5.1.1. Manglares

Los manglares son formaciones vegetales litorales características de las zonas ribereñas en regiones tropicales y subtropicales, que han sido definidas como terrenos costeros arbolados, bosques de marismas y manglares que generalmente están constituidos por árboles y arbustos que se desarrollan por debajo del nivel más alto de la marea (Hogarth, 1999, como se citó en INVEMAR y CVC, 2007).

En el pacífico colombiano habitan diferentes especies de manglar como lo son *Avicennia germinans*, *Rhizophora mangle*, *Laguncularia racemosa*, *Conocarpus erectus*, *Pelliciera rhizophorae*, *Rhizophora harrisonii* Leechman, *Rhizophora racemosa*, *Avicennia bicolor* y *Mora oleifera*. Estos se distribuyen en un sector aproximadamente continuo, que va desde el río Mataje al sur del departamento de Nariño, hasta las inmediaciones de Cabo Corrientes en el departamento del Chocó, donde se discontinúa y luego se extiende con fragmentos cortos en el Golfo de Tribugá, Ensenada de Utría y en Juradó, en límites con el espacio geográfico de Panamá (IDEAM, 2015).

El monitoreo de manglares es considerado como una parte esencial de la estrategia de conservación de la biodiversidad, en los cuales se identifican ciertos objetivos, de acuerdo con INVEMAR (2007) determinó “conocer el crecimiento de la vegetación permitiendo extraer elementos importantes en el manejo y conservación de estos ecosistemas; evaluar la diversidad del conjunto de aves que anidan en los manglares; evaluar el estado poblacional de ciertos organismos que habitan la fauna intermareal de importancia económica como moluscos y crustáceos; renovar el proceso de definición de áreas para el ordenamiento ambiental de los bosques de manglar en consenso con las comunidades de grupos étnicos vinculadas a estas zonas; y finalmente, fortalecer y optimizar la identificación, observación y análisis del contenido generalizado de los ecosistemas de manglar y su interacción entre la flora, la fauna, los factores fisicoquímicos y socioculturales. Esto debido a que el proceso de monitoreo posibilita recolectar datos que han pasado por una etapa de procesamiento y análisis cuyo propósito es exponer un concepto comparativo sobre el desarrollo del recurso a través de un tiempo definido (Goldsmith, 1991, como se citó en Restrepo, 2007).

5.1.2. Percepción Remota

La percepción remota es una ciencia que posibilita identificar y analizar las características de atributos de la superficie terrestre estando a cierta distancia de ellos. Los datos provenientes de los sensores remotos que son medidos en energía emitida o reflejada por la superficie terrestre son transformados en datos en forma de fotografías aéreas, imágenes de satélites, entre otros. (Harris, 1987; FCAGR, 2011, como se citó en Rodríguez et al., 2018). También ha sido definida como la medición de la energía que es emanada desde la superficie de la Tierra; determinando a la energía medida por el Sol, como teledetección pasiva, cuyo resultado puede ser una imagen digital. Y la energía emitida desde el sensor de la plataforma es definida como teledetección activa, por ejemplo, los sensores que utilizan microondas (Richards y Jia, 2006).

En cuanto a las imágenes satelitales, la energía registrada por el sensor se transforma a nivel digital, para después pasar a radiancia, reconocida como la cantidad de energía radiada en una dirección, por unidad de área y ángulo sólido, y luego a reflectancia, la cual es determinada como la energía reflejada. (Chuvieco, 2008)

5.1.2.1 Sensores Analizados

Satélite Landsat

Las misiones Landsat se componen de ocho satélites operativos de observación de la Tierra que utilizan sensores remotos para recopilar datos e imágenes del planeta tierra como parte del Programa Nacional de Imágenes Terrestres (NLI) del Servicio Geológico de EE. UU. (USGS).

Landsat 5 cargaba los sensores Multispectral Scanner (MSS) y Thematic Mapper (TM), tenía como misión transmitir imágenes de las condiciones de la superficie terrestre en todo el mundo.

Tabla 2. Longitudes de onda y resolución de las bandas, Landsat 5 TM

Número de banda	Longitud de ondas (micrómetros)	Resolución (metros)
1	0,45 – 0,52	30
2	0,52 – 0,60	30
3	0,63 – 0,69	30
4	0,76 – 0,90	30
5	1,55 – 1,75	30
6	10,41 – 12,5	120
7	2,08 – 2,35	30

Fuente: NASA, 2015

Agregando a lo anterior la misión Landsat 7 ETM + tiene el objetivo principal de proporcionar datos oportunos, de alta calidad, visibles, infrarrojos y de longitud de onda térmica de todas las áreas terrestres y cercanas a la costa de la Tierra y, por lo tanto, actualizar continuamente el archivo Landsat existente, ver (Tabla 3).

Las imágenes de esta misión se entregan con una resolución radiométrica de 8 bits con 256 niveles de gris.

Tabla 3. Longitudes de onda y resolución de las bandas, Landsat 7 ETM+

Número de banda	Longitud de ondas (micrómetros)	Resolución (metros)
1	0.45 – 0.515	30
2	0.52 – 0.605	30
3	0.63 – 0.69	30
4	0.76 – 0.90	30
5	1.55 – 1.75	30
6	10.40 – 12.5	60*
7	2.08 – 2.35	30
9	0.520 – 0.900	15
*La banda 6 se tiene 60 metros, luego es remuestreada a 30 metros para que coincida con las bandas reflectantes ETM +		

Fuente: NASA, 2019

De acuerdo con una falla que se presentó en el año 2003, en el Scan Line Corrector (SLC), que compensa el movimiento de avance del satélite, que no fue posible corregir, la línea de visión del sensor traza un patrón en zigzag en sentido longitudinal del recorrido terrestre del satélite, esto conlleva a una dualidad de la extensión de la imagen, cuyo ancho aumenta hacia el margen de la escena, al procesar los datos de nivel 1, las extensiones duplicadas son eliminadas, dejando espacios vacíos en los datos. Si bien estas escenas solo tienen el 78% de sus píxeles restantes posterior a la eliminación de las áreas duplicadas, su precisión tanto geométrica como radiométrica está entre las más precisas de los datos de satélites existentes. (NASA, 2008)

Sensor Thematic Mapper TM

Es un sensor avanzado para uso terrestre que permite captar diferentes espectros de luz y de acuerdo con su diseño faculta obtener una resolución de imagen mejorada, una separación espectral más precisa, una exactitud geométrica optimizada y una mayor precisión y resolución radiométrica que el sensor del sistema de escáner multispectral (MSS). Los datos de TM son captados al mismo tiempo en siete bandas espectrales, ver (Tabla 2).

La radiación térmica es captada por la banda 6 y sólo se obtiene en escenas nocturnas con un campo de visión instantáneo al suelo de 120 m X 120 m, y para las bandas 1, 2, 3, 4, 5 y 7 es de 30 m X 30 m. (NASA, 2015)

Sensor Enhanced Thematic Mapper Plus ETM

Como señala NASA (2015), el sensor ETM es un radiómetro fijo de barrido multiespectral de ocho bandas que provee información de imágenes de alta resolución de la superficie de la Tierra, de modo que detecta radiación filtrada espectralmente en las bandas visibles a infrarrojo, infrarrojo de onda corta, infrarrojo de onda larga y pancromáticas de la superficie de la tierra irradiada por el sol en una franja de 183 km de ancho orbitando a una altura de 705 km.

Desde el punto de vista de Rodríguez, et al., (2018), para el estudio de ecosistemas de manglar, las regiones que muestran mayor relevancia son el visible, cuyas longitudes de onda es de 0.4 a 0.5 μm para la banda azul, 0.5 a 0.6 μm para la banda verde, 0.6 a 0.7 μm para la banda roja, así mismo, la región del infrarrojo cercano tiene longitudes de onda de 0.7 a 1.3 μm , la del infrarrojo de onda corta de 1.3 a 2.5 μm e infrarrojo medio de 2.5 a 8 μm .

5.1.2.2 Correcciones a imágenes de satélite

Correcciones Geométricas

Esta corrección busca conseguir que cada píxel se encuentre en el punto planimétrico respectivo, puesto que la ajustada posición de los píxeles de una imagen respecto a un sistema de coordenadas definido, es determinante para que los datos satelitales estén correctamente correspondido con los objetos del terreno para cualquier necesidad que requiera el manejo de datos cuantitativos y cualitativos además, determina la condición de utilizar los datos de satélites para monitorear los procesos que vinculen a ecosistemas y la captura de las posibles variaciones. (Moncayo, 2017)

Correcciones Atmosféricas

La corrección atmosférica tiene como propósito eliminar el efecto de los aerosoles, partículas suspendidas, además del vapor de agua y la radiancia intrínseca introducida en el sensor la cual se irradia en la imagen como producto de la relación del sensor con la atmosfera. (Aguilar, 2014).

El efecto de dispersión atmosférica no es constante en el tiempo y espacio, es decir, no es homogénea a la imagen, pues solo afecta algunas partes de la imagen por las diferentes longitudes de onda de la señal de radiación magnética. (Hernández, 2019).

Correcciones Radiométricas

La corrección radiométrica es un proceso de restauración de píxeles con información perdida o defectuosa, por tanto, es necesario que en la corrección se realice un proceso de transformación de los niveles digitales originales a radianes (parámetros físicos), obteniendo valores de intensidad homogéneos, equilibrando el histograma y logrando corregir imperfecciones presentes en los *píxeles* de una imagen (Chuvieco, 1995, como se citó en Hernández, 2019). En este proceso se aplican técnicas para la corrección radiométrica como lo son:

- a) Restauración de líneas o píxeles estimando los valores de los píxeles perdidos considerando los niveles digitales de los píxeles vecinos más cercano; promediando los valores de las líneas anterior y posterior a la línea que presenta errores; y con el uso de una banda auxiliar que estima el valor de los píxeles defectuosos.
- b) Correlación mediante el bandeo de la imagen, con esta técnica las fallas en la calibración de los detectores en un sensor de tipo barrido provocan que algunas bandas se observen más claras u oscuras, principalmente en las zonas de baja radiancia (áreas marítimas) en comparación con el resto de bandas. Para ello, se utiliza la corrección también conocida como corrección de bandeo, que corrige los histogramas de cada detector mediante cálculos de coeficientes y correlaciones entre los detectores.
- c) Conversión de ND a parámetros físicos, relacionado con el comportamiento físico de la superficie captada en la imagen (humedad de la vegetación, biomasa, temperaturas, etc.)

5.1.2.3 Optimun Index Factor (OIF)

El OIF, es una técnica sencilla que se utiliza con frecuencia para precisar el compuesto de tres bandas en la imagen, pudiendo seleccionar la que presente mejor respuesta espectral mediante procesos estadísticos (Purwanto, 2020).

Desde el punto de vista de Patel et al., (2011), las características espectrales de la imagen de satélite determinadas mediante el OIF cuyos valores correspondan a los más altos son confiables para realizar una clasificación, puesto que tienden optimizar la precisión, así pues, como señala González et al., (2003) el OIF considera que la composición de bandas más rigurosa para realizar la clasificación es la de mayor varianza y se calcula a través de la ecuación (1).

$$OIF = \frac{\sum_{i=1}^3 S_i}{\sum_{j=1}^3 |R_j|} \quad (1)$$

Donde:

S_i = Desviación típica de la banda i

R_j = Coeficiente de correlación entre dos bandas j

5.1.2.3.1 Combinación sin repeticiones

De acuerdo con Sarmiento y Fernández (2014), se entiende por combinaciones sin repeticiones a los distintos conjuntos con posibilidad de formarse con los n elementos de un conjunto, definidos de k en k, de tal manera que dos conjuntos difieren entre sí cuando comparten al menos un elemento distinto. No se tiene en cuenta el orden, lo cual significa que, una combinación de tamaño k de un conjunto de n elementos es cualquier subconjunto que tenga k elementos.

$$nC_r = \frac{n!}{(n-r)!r!} \quad (2)$$

Donde:

n = número de bandas usadas en la imagen de satélite

r = tamaño de la muestra

5.1.3. Índices de Vegetación

Índice de Vegetación Normalizada (NDVI)

Para estimar la cantidad y calidad de los bosques de manglares desde las imágenes satelitales se debe conocer el índice diferencial de vegetación normalizada (NDVI), el cual presenta alta correlación con las variables forestales (Hernández et al., 2020).

$$NDVI = \frac{(NIR-R)}{(NIR+R)} \quad (3)$$

Donde: NDVI = índice de diferencia normalizada

R = banda rojo

NIR = banda infrarrojo cercano

Vale la pena señalar, el planteamiento de la NASA, donde sostiene que todos los índices de vegetación de los satélites aplican la fórmula de diferencia para cuantificar la densidad del crecimiento de las plantas en la tierra.

Así, los cálculos del NDVI para un píxel siempre se obtiene como resultado un valor entre -1 y +1, no obstante, el verdor de una hoja nunca dará un valor cercano a cero, puesto que un cero representa que no existe vegetación y cerca de +1, por ejemplo,

un valor entre 0,8 y 0,9 indica la mayor densidad posible de vegetación. Por tanto, es imprescindible el cálculo de este índice pues permite identificar la concentración de manglares de la zona de estudio.

Índice de vegetación ajustado al suelo (SAVI)

Para este tipo de proyecto es necesario identificar la extensión de suelo con baja vegetación, por ende, es importante tener en cuenta el índice de vegetación ajustado al suelo (SAVI) desde la ecuación (4). (Roy et al., 2019)

$$SAVI = ((1 + L) * (NIR - R)) / (NIR + R + L) \quad (4)$$

Donde:

SAVI = índice de vegetación ajustado al suelo

R = banda rojo, NIR = banda infrarrojo cercano.

L = Factor de corrección del brillo de suelo, el cual varía por la cantidad de vegetación verde.

Este factor de corrección (L) se estima entre 0 y 1, en el que 0 implica regiones con vegetación muy alta y 1 sin regiones de vegetación verde.

Índice de agua de diferencia normalizada (NDWI)

Por la ubicación de los manglares en zonas intermareales es necesario tener en cuenta el índice de agua de diferencia normalizada (NDWI), y se calcula a partir del índice de canales de infrarrojo cercano NIR donde se presenta menor reflectancia la cual se ve afectada por la estructura interna de la hoja y el contenido de materia seca de la hoja, pero no por contenido de agua, además de la región del verde cuyo comportamiento de la energía en el agua presenta mayor reflectancia.

Para este índice los resultados varían entre -1 a 1, donde los elementos de agua tienen valores positivos, mientras la vegetación y otros elementos del suelo tienden a cero o a valores negativos (Ceccato et al., 2001) y (Rodríguez et al., 2018). Se calcula mediante la ecuación (5)

$$NDWI = (\rho_{Green} - \rho_{NIR}) / (\rho_{Green} + \rho_{NIR}) \quad (5)$$

Donde:

NDWI = Índice de agua de diferencia normalizada

ρ_{Green} = reflectancia en el verde

ρ_{NIR} = reflectancia en el infrarrojo cercano

Índice de Agua de Diferencia Normalizada Modificado

Este índice que modifica al NDWI, determina que se cambie la región del infrarrojo cercano por la región del infrarrojo medio, teniendo en cuenta que en esta región espectral el agua absorbe más que en el infrarrojo cercano, y tiene el propósito de aumentar la diferencia existente entre la reflectancia del agua y de la vegetación, suelo y edificaciones. (Rodríguez et al., 2018)

$$MNDWI = \frac{\rho_{Green} - \rho_{MIR}}{\rho_{Green} + \rho_{MIR}} \quad (6)$$

Donde:

ρ_{MIR} = corresponde a reflectancia de infrarrojo medio

Índice de Vegetación de Manglar MVI

El índice MVI combina las bandas del visible e infrarrojo para medir la probabilidad de que un píxel de la imagen sea un manglar al extraer la información de verdor y la humedad de las bandas verde, NIR y SWIR1 (Baloloy et al., 2020).

$$MVI = \frac{NIR - V}{SWIR1 - V} \quad (7)$$

Donde:

$SWIR1$ = corresponde a la banda infrarrojo de onda corta

V = corresponde a la banda verde

Entonces, con los índices calculados es posible obtener los manglares con sus respectivas categorías de forma precisa, además, con el proceso de diferenciación entre el NDVI y el SAVI, se podrá extraer extensión de manglares con mayores detalles (Roy et al., 2019).

5.1.4. Clasificación Supervisada

De acuerdo con Congedo (2021), la clasificación semi-automática o clasificación supervisada es un método para procesar imágenes de modo que permita identificar elementos tangibles en una imagen mediante firmas espectrales; y sostiene que hay varios tipos de algoritmos para clasificar una imagen, de manera que se pueda generar un mapa temático de la cobertura del suelo. Así mismo, para procesar imágenes y realizar análisis espacial con Sistema de Información Geográfica (SIG) es necesario el uso de un software específico, tal como el Semi-Automatic Classification Plugin de QGIS.

5.1.4.1. Algoritmos del SCP

El algoritmo de máxima probabilidad calcula las distribuciones de probabilidad para las clases, relacionadas con el teorema de Bayes, en ello evalúa si un píxel

corresponde a una clase de cobertura terrestre. Para la aplicación de este algoritmo se requiere una cantidad adecuada de píxeles por área de entrenamiento, facilitando el cálculo de la matriz de covarianza (Congedo, 2021).

La función discriminante se calcula para cada píxel como:

$$gk(x) = \ln p(C_k) - \frac{1}{2} \ln |\Sigma_k| - \frac{1}{2} (x - y_k)^t \Sigma_k^{-1} (x - y_k) \quad (8)$$

Donde:

C_k = clase de cobertura terrestre

x = vector de firma espectral de un píxel de imagen

$p(C_k)$ = probabilidad

$|\Sigma_k|$ = determinante de la matriz de covarianza de los datos en clase C_k

Σ_k^{-1} = inversa de la matriz de covarianza

y_k = vector de firma espectral de clase k

En cuanto al algoritmo de mínima distancia, Congedo (2021), describe que este calcula la distancia Euclídea a través de las firmas espectrales de los píxeles de la imagen y las del área de entrenamiento y está definida mediante la ecuación (9).

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (9)$$

Donde:

x = vector de firma espectral de un píxel de imagen

y = vector de firma espectral del área de entrenamiento

n = número de bandas de la imagen

Así mismo, el algoritmo de mapeo del ángulo espectral utiliza las firmas espectrales de los píxeles de la imagen y las de las áreas de entrenamiento, para el cálculo del ángulo espectral mediante la ecuación (10).

$$\theta(x, y) = \cos^{-1} = \left(\frac{\sum_{i=1}^n x_i y_i}{\left(\sum_{i=1}^n x_i^2 \right)^{\frac{1}{2}} \left(\sum_{i=1}^n y_i^2 \right)^{\frac{1}{2}}} \right) \quad (10)$$

Donde:

x = vector de firma espectral de un píxel de imagen

y = vector de firma espectral del área de entrenamiento

n = número de bandas de la imagen

5.1.4.2. Matriz de Confusión

Es una matriz cuadrada en la que se relaciona la clasificación de la imagen con la verdadera de terreno, a través de esta se evalúa la exactitud de la clasificación, situando en las filas las clases del mapa y en las columnas las clases para la verdad de terreno o campo (Tabla 4). Con esta matriz se puede identificar las asignaciones de las clasificaciones correctas definidos en los elementos de la diagonal y las migraciones que son los elementos ubicados fuera de la diagonal. También permite obtener los denominados errores de omisión y de comisión, mientras que los primeros reportan los elementos que hacen parte de tal clase no se encuentran en ese grupo debido a errores incluidos en otra, los segundos reportan elementos que no hacen parte a esa clase y están en ella (Boca y Rodríguez, 2012).

Tabla 4: Esquema general de la matriz de confusión

CLASES MAPA	CLASES EN EL CAMPO					Total mapa	EXACTITUD USUARIO	ERROR COMISIÓN
	A1	A2	...	AM				
	A1	a_{11}^*	a_{12}	...	a_{1m}	$a_{.1}$	$a_{.1}/a_{..}$	$1-(a_{.1}/a_{..})$
	A2	a_{21}	a_{22}	...	a_{2m}	$a_{.2}$	$a_{.2}/a_{..}$	$1-(a_{.2}/a_{..})$
	...			...				
	AM	a_{m1}		...	a_{mm}	$a_{.m}$	$a_{.m}/a_{..}$	$1-(a_{.m}/a_{..})$
	Total campo	$a_{1.}$	$a_{2.}$	...	$a_{2.}$	$a_{..}$		
	EXACTITUD PRODUCTOR	$a_{1.}/a_{..}$	$a_{2.}/a_{..}$	...	$a_{m.}/a_{..}$			
	ERROR OMISIÓN	$1-(a_{1.}/a_{..})$	$1-(a_{2.}/a_{..})$	...	$1-(a_{m.}/a_{..})$			

Fuente: Boca y Rodríguez, 2012

Hudson (1987) citado por Vásquez (2019) menciona que el índice estadístico Kappa, el cual permite evidenciar la confianza de una clasificación además de la articulación entre las diferentes clases. Incluso, permite cuantificar la exactitud de la clasificación indicando la correlación entre el mapa obtenido y la información real del terreno, obteniendo de forma aleatoria la contribución. Este índice lo define la ecuación (11).

$$K = \frac{P(a) - P(e)}{1 - P(e)} \quad (11)$$

Donde:

$P(a)$ es la porción de píxeles correctamente clasificados

$P(e)$ es la probabilidad hipotética de clasificaciones correctas al azar.

Desde el punto de vista de (Landis & Koch, 1977), con el índice kappa se identifica el grado de concordancia del resultado obtenido, esta relación es definido en la tabla 5.

Tabla 5: Escala de valoración índice Kappa

Índice de Kappa	Grado de Concordancia
< 0,0	Sin relación
0,01 – 0,20	Leve
0,21 – 0,40	Aceptable
0,41 – 0,60	Moderado
0,61 – 0,80	Considerable
0,81 – 1,00	Casi perfecto

Fuente: Landis & Koch, 1977

5.1.5. Quantum GIS (QGIS)

Es un programa de libre acceso, cuyo objetivo radica en ser un SIG de uso sencillo, que proporcione funciones y características comunes.

Inicialmente su objetivo era proveer un visor de datos SIG, pero ha presentado un proceso de desarrollado, puesto se está utilizando para las necesidades diarias de visualización de datos SIG, para la captura de datos, para el análisis SIG avanzado y para presentaciones en forma de mapas, atlas e informes sofisticados. También ofrece diversas funcionalidades sobre sistemas de información geográfica y percepción remota debido a sus características principales admite diferentes formatos de datos representados vectoriales y ráster, con un nuevo soporte de formato que se agrega fácilmente mediante la arquitectura del complemento.

QGIS tiene licencia pública general GNU (GPL), y al desarrollar QGIS bajo esta licencia significa que puede inspeccionar y modificar el código fuente, también garantiza el acceso a un programa GIS gratuito que se puede modificar libremente (QGIS, 2020).

5.1.5 Metodología Corine Land Cover

Es una metodología para el inventario de la cobertura de la tierra cuya base de datos constituye un soporte para la toma de decisiones en políticas relacionadas con el medio ambiente y el ordenamiento territorial; esta permite describir, caracterizar,

clasificar y comparar las características de la cobertura de la tierra, interpretadas a partir de la utilización de imágenes de satélite de resolución media (Landsat), para la construcción de mapas de cobertura a escala 1:100.000.

El proceso metodológico Corine Land Cover se desarrolla mediante las etapas de adquisición y preparación de la información; análisis e interpretación de las coberturas; verificación de campo, control de calidad y generación de la capa temática (IDEAM, 2008).

5.2. Marco Referencial

Los manglares son los ecosistemas más amenazados y vulnerables del mundo, incluso han experimentado una pérdida progresiva durante los últimos cincuenta años. (Kuenzer et al., 2011). Por consiguiente, se han desarrollado diversas técnicas para el análisis de manglares, desde la interpretación visual hasta el procesamiento automatizado. (Rodríguez et al., 2018).

Vale la pena señalar que el acercamiento a la temática a partir de diferentes trabajos académicos y/o de investigación, permite su importancia desde la teledetección como herramienta para proporcionar información espacio-temporal sobre los estudios de manglares. (Kuenzer et al., 2011).

Para precisar en este referente, es importante centrarse en Buenaventura, Valle del Cauca, de acuerdo con García (2012), el manglar es el ecosistema costero que presenta mayor fragilidad, por lo que es fundamental realizar los monitoreos necesarios ya que dichos ecosistemas frecuentemente son amenazados por la influencia humana y el cambio climático, para ello es importante contar con información suficiente de todo el ecosistema y así aportar en la protección y conservación de estos recursos naturales, ahora bien, la obtención de la información indicada la pudo obtener a partir de la técnica de sensores remotos, utilizando imágenes de satélite del sensor Landsat TM del distrito Buenaventura en el año 2011, además para garantizar mayor precisión en la información obtenida este trabajo fue apoyado con imágenes de satélite del sensor ETM del año 2001 por las condiciones de nubosidad que regularmente se presenta en el pacífico colombiano, así mismo, el autor utilizó información secundaria vectorial para la obtención de la información que permitiera comparar las coberturas de manglar.

En este trabajo, para la actualización de la cobertura de manglar (tabla 6), el autor utilizó un método de clasificación orientado a objetos a partir de algoritmos de agrupación de píxeles coincidentes, e inició con un preprocesamiento en el que se realizó una restauración de las imágenes para mejorar la resolución en las bandas espectrales excepto la térmica pasándola de 30 metros a 10 metros, realizó la corrección radiométrica para corregir la degradación de la imagen, la corrección atmosférica para eliminar los efectos de la atmósfera a partir del algoritmo FLAASH, y la corrección geométrica para darle una posición geográfica a los píxeles de la

imagen; seguidamente, el procesamiento inició con el realce de la imagen de manera que permitiera resaltar las características a partir del filtro lineal al 2% logrando separar el manglar de otras coberturas, luego mediante el algoritmo de agrupamiento de datos no supervisado ISOSEG realizó la clasificación de las imágenes cuyo resultado se obtuvo con un umbral de aceptación del 95%, finalmente obtuvo los polígonos de cobertura los cuales fueron revisados y se realizó la generalización desde el número mayor de clases generadas, aquí es importante indicar que el autor recomendó la validación de los polígonos de manglar a partir de salidas de campo y monitoreo de las parcelas de manglar.

Tabla 6. Comparativo áreas de manglar generadas por la CVC, 2012 vs 2001.

Cuenca Hidrográfica	Manglar CVC– 2012 Área (has)	Manglar CVC– 2012 Área (%)	Manglar CVC– 2001 Área (has)	Manglar CVC– 2001 Área (%)	Diferencia Manglar CVC 2012 vs 2001 Área (has)	Diferencia Manglar CVC 2012 vs 2001 Área (%)
Bajo San Juan	673,7	2,1%	562,9	1,8%	110,8	0,35%
Bahía Málaga	4549,9	14,2%	3823,3	11,9%	726,6	2,32%
Bahía Buenaventura	1984,5	6,2%	1910,4	6,0%	74,1	0,26%
Dagua	1314,4	4,1%	1558,4	4,9%	-244,0	-0,74%
Anchicayá	6200,6	19,4%	6547,8	20,4%	-347,2	-1,00%
Raposo	4504,7	14,1%	4779,6	14,9%	-274,9	-0,80%
Mayorquín	991,7	3,1%	990,2	3,1%	1,5	0,02%
Cajambre	5217,0	16,3%	5065,22	15,8%	151,7	0,54%
Yurumanguí	3763,0	11,8%	4148,9	12,9%	-385,9	-1,16%
Naya	2742,8	8,6%	2686,3	8,4%	56,5	0,21%
Total	31942,22	100%	32073,02	100%	-130,8	0,0%

Fuente: García, 2012

Heenkenda et al., (2014), presentaron una investigación soportada en la comparación de imágenes del satélite WorldView-2 (WW2) y fotografías aéreas de alta resolución para separar manglares conforme a la especie. Ellos manifestaron que los manglares son determinados como uno de los hábitats más amenazados del mundo, puesto que la degradación y la limpieza de los hábitats de manglares que se produce a escala mundial por la urbanización, el aumento demográfico, la desviación del agua, la acuicultura y la construcción de estanques de sal han afectado directamente los ecosistemas de manglar, en consecuencia, determinaron que el uso de la teledetección en el mapeo de manglares para identificar diferentes especies en un área de estudio presenta ciertos desafíos, por lo que es necesario incluir la consideración de la resolución espacial y espectral ideal para las especies de manglar.

Este trabajo propone investigar el potencial del uso de datos de teledetección de alta resolución espacial para la identificación de las diferentes especies de

manglares mediante el algoritmo Support Vector Machine (SVM), además de relacionar la precisión de los resultados con WW2 y con fotografías aéreas, de modo que permita identificar el método más preciso, para ello definieron como zona de estudio el bosque de manglar Rapid Creek en Darwin norte de Australia, por consiguiente, obtuvieron imágenes de satélite del año 2010 con ocho bandas multiespectrales a 2 metros y una banda pancromática con 0,5 metros de resolución espacial respectivamente; para el proceso de comparación utilizaron fotografías aéreas en color verdadero del año 2010 de la cámara digital UltraCamD, posteriormente, realizaron las correcciones radiométricas a las imágenes WW2 usando el software ENVI 5.0, las fotografías aéreas se georreferenciaron mediante coeficientes polinomiales, para la resolución espacial y espectral aplicaron un filtro paso alto y en consecuencia la imagen multiespectral WW2 redujo la resolución espacial a 0,5 metros. En cuanto a los procesos fotogramétricos se hicieron a través del programa ERDAS (LPS), la clasificación de las imágenes WW2 y las fotos aéreas fueron realizadas a través del software eCognition Developer 8.7 para luego ser refinado con el software ENVI, seguidamente la separación de zonas con manglares y sin manglares lo hicieron a través del análisis de imágenes basados en objetos OBIA, también utilizaron el índice de vegetación de diferencia normalizada NDVI para la separación final de los manglares, no obstante, al aplicar el OBIA a las fotografías aéreas fue limitado por el ancho de banda y el número de bandas espectrales, por lo que el proceso se hizo finalmente de forma manual. Para finalizar clasificaron las especies de manglar extraídos utilizaron el algoritmo SVM, puesto que este, localiza un mejor límite no lineal en un espacio cuyas características son de mayor dimensión. La validación fue realizada a través del trabajo de campo a partir de 560 puntos tomados de forma aleatoria.

Como resultado identificaron cinco especies diferentes de manglares, por otra parte, la clasificación de las fotos aéreas presentó diferencias en relación con las clasificaciones WW2, ya que las clases obtenidas en las fotos aéreas no captó la zonificación de manglares a partir de los estudios previos, además el mapa obtenido a partir de las imágenes WW2 representa mejor patrón de zonificación de las diferentes especies de manglares

Se concluyó que la precisión es mayor con imágenes WW2 la cual fue del 89% mientras que con las fotografías aérea donde la precisión general fue del 68%, en cuanto al mapeo de especies de manglares utilizando el algoritmo SVM determinó que el resultado de los datos fue mejor con las imágenes satélites que con las fotografías aéreas.

Otros estudios como es el realizado por Vásquez (2019), en su tesis de maestría propuso una metodología para el mapeo de manglares en el departamento del Chocó utilizando imágenes de satélite Sentinel-1 el cual contiene un radar de apertura sintética (SAR) de banda C que ofrece datos de gran resolución en zonas costeras que presentan nubosidad. Por consiguiente, consideró que la teledetección es de gran eficacia tanto para identificar como determinar zonas de estudio y de monitoreo en ecosistemas de manglar de manera precisa, así pues, propuso

mapear la extensión de manglares de la región sur del pacífico Chocoano permitiendo integrar datos de la parte eco reflejada en la orientación de la antena denominada retrodispersión y técnicas polarimétricas de imágenes Sentinel-1, incluyendo la altura de la misión topográfica Radar Shuttle (SRTM).

Con el propósito de responder la pregunta orientadora de *¿Cómo emplear datos polarimétricos de imágenes Sentinel 1 para la clasificación de la cobertura de manglar del Sur del Pacífico Chocoano?*, diseñó e implementó una metodología de clasificación de cobertura de manglar con imágenes Sentinel-1 de la polarización VH transmisión vertical, recepción horizontal y la polarización VV transmisión vertical, recepción vertical. Para el procesamiento utilizó el software de acceso libre SNAP (Sentinel Application Platform) versión 6.0 y la plataforma ArcMap, aquí es importante señalar que el proceso metodológico está basado en tres enfoques, por un lado el de retrodispersión para la eliminación del ruido térmico y la calibración radiométrica, en ello, realiza la corrección geométrica y finaliza con la generación de índices; por otro lado, el enfoque polarimétrico consistió en preparación de la imagen aplicando la matriz de covarianza con las polarizaciones VH y VV, eliminando el ruido sal y pimienta, posteriormente la descomposición polarimétrica para las condiciones de ruido y resolución espacial y se compensó las distorsiones de la variación topográfica con la corrección geométrica; luego con el enfoque propuesto realizó un corregistro de las imágenes procesadas para compilar las bandas, siguiendo con la definición de áreas de entrenamiento para luego realizar la clasificación con el método Random Forest.

Finalmente, con el enfoque propuesto obtuvo una precisión por encima del 94%, superando a los enfoques retrodispersión y polarimétrico. Vale la pena señalar que la validación usada por Vásquez (2019) muestra que la matriz de confusión indica que el enfoque propuesto tiene mejor exactitud que los otros enfoques, teniendo en cuenta que la exactitud del enfoque propuesto es de 80,25%, mientras que el de retrodispersión es de 46,75% y polarimétrico es de 43,50%.

Flores et al., (2011), evaluó el diagnóstico y retrospectiva del estado de salud de bosques de manglares en una construcción de lagunas en el Estado de Sinaloa, México usando imágenes de satélite Landsat TM 5 considerando su importancia ecológica y socioeconómica. Teniendo en cuenta los factores de variación climática y ambientales a las que está expuesta la zona de estudio, específicamente el fenómeno del niño que posiblemente afectarían la estructura y funcionamiento ecológico de la vegetación manglar.

Para ello, utilizaron las reflectancias de las bandas rojo e infrarrojo que les permitió calcular el índice de vegetación normalizada NDVI el cual mejora la sensibilidad de la detección de vegetación verde, y lo compararon con el NDVI obtenido en campo cuyos datos se tomaron del espectrómetro FieldScout CM 1000, así pues, identificaron la colinealidad entre la concentración de clorofila y el NDVI obtenido en campo, por lo que reconocieron la importancia del NDVI para identificar la salud de los manglares.

De acuerdo con Shimu et al., (2019), los resultados de clasificación de una imagen con sensores remotos no son suficiente para detectar los cambios usando el método de post clasificación, por consiguiente, proponen una técnica de captura de cambios en los bosques de manglar de Sudurban entre los países de Bangladesh y la India para los años 2011 y 2019 soportado en el índice de vegetación normalizada NDVI. Debido a que el manglar más grande del mundo como es conocido el manglar de Sudurban, está amenazado por factores estresantes tanto naturales como antropogénicos, que además incluye la sobreexplotación de la madera y la contaminación, la erosión costera, el aumento de la salinidad, el cambio climático, el aumento del nivel del mar y la reducción del flujo de agua dulce.

La propuesta que consiste en una técnica de detección de cambios a partir del NDVI realiza un índice de floras para representar la cantidad de área que tiene mucha vegetación y si el crecimiento de vegetación es posible o no, fue realizado con el uso de imágenes Landsat 7 ETM. Y a partir del NDVI clasificaron las imágenes para luego realizar la comparación con la imagen de referencia y así generar un reporte de los cambios entre los años analizados; los criterios basados en el NDVI muestran que este índice se mide con valores entre -1 y 1, donde 1 representa mucha vegetación, los valores entre 0 y 1 representa el área con vegetación, así mismo para valores entre 0 y -1 representa el área sin vegetación. En la clasificación definieron cuatro clases siendo de alta vegetación, vegetación, sin vegetación y agua, de allí pues encontraron cambios progresivos para alta vegetación y vegetación, y cambios regresivos para agua y sin vegetación. Al hacer el análisis variacional hallaron que el nivel de la vegetación alta es del 0,02% y la vegetación es del 19.22%, en cuanto a la clase agua disminuyó inicialmente del 84.14% al 54.28%, pero finalmente aumentó del 54.28% al 66.84%.

Mas adelante, con el artículo “Desarrollo y aplicación de un nuevo índice de vegetación de manglares (MVI) para el mapeo rápido y preciso de manglares”, Baloloy et al., (2020), propone el nuevo índice de vegetación de manglares MVI para mapear de forma rápida y precisa extensiones de manglar utilizando los sensores remotos, este nuevo índice utiliza las reflectancias de las bandas verde, infrarrojo cercano (NIR) e infrarrojo de onda corta (SWIR) del satélite Sentinel 2, de manera que permita discriminar los manglares de otras coberturas de suelo.

El MVI se calcula dividiendo la diferencia entre la banda NIR y la banda verde, la cual captura las diferencias de verdor entre los bosques de manglares y la vegetación terrestre, y la diferencia de la banda SWIR y el verde, la cual expresa la humedad distinta de los manglares sin necesidad de datos intermareales adicionales; en el cálculo del MVI evaluaron su precisión para las diferentes zonas de estudio a través de trabajo de campo y ortofotos de alta resolución para así generar la extensión de manglares de la zona de estudio. Este índice ha sido adecuado, puesto que ha podido diferenciar manglares de otras coberturas con una precisión del 92%.

Finalmente, Roy et al., (2019), basaron su análisis en el mapeo y monitoreo de los cambios espacio-temporales de los manglares en una extensión de 480 kilómetros, a lo largo de la costa de Odisha de La India, a partir de imágenes Landsat 5 TM, Landsat 7 ETM y Landsat 8 OLI en los períodos 1990, 2000, 2009 y 2015, para ello se basaron en los índices de vegetación NDVI, NDWI y SAVI, teniendo en cuenta tres características de clasificación, como lo son manglares densos, manglar escaso y manglar abierto. Con la radiancia convertida en reflectancia atmosférica para una mayor precisión en la identificación de manglares, calcularon los respectivos índices, de modo que el NDVI extraído se sustrajo del SAVI pudiendo obtener una extensión de manglar más nítida, el cual les permitió encontrar un aumento progresivo en la cobertura de manglar del período de tiempo analizado, puesto que para el año 1990 habían 18573.49 has, al año 2000 identificaron 20689.29 has y para el año 2015 identificaron 23871.49 has, esto permitió clasificar esta cobertura vegetal, precisando la cantidad en hectáreas para el año 2015 de 7146.14 de manglar denso, 12327.76 de manglar disperso y 4397.6 de mangle abierto, diferente al año 1990 cuyas áreas en hectáreas fueron de 6019.14 para manglar denso, 8145.22 para manglar disperso y 4409.13 para manglar abierto. Este aumento en la cobertura de manglar se ha dado por el trabajo organizado de recuperación del ecosistema mediante reforestación, restauración y concientización del manejo costero.

6. MATERIALES Y ÁREA DE ESTUDIO

6.1. Reconocimiento y delimitación de la zona de estudio

La costa pacífica colombiana es una región con grandes ventajas respecto a la biodiversidad, puesto que cuenta con una variedad de recursos naturales entre ellos están los manglares; estos ecosistemas de manglar son considerados territorios ancestrales, por consiguiente, representan para las comunidades negras e indígenas de la costa pacífica vallecaucana, una posibilidad económica, social y cultural desde hace varias décadas. Su relación histórica y actual con el manglar se basa en la explotación tradicional de los recursos forestales (taninos, madera y leña) e hidrobiológicos asociados, a través de la extracción de piangua, cangrejo, pescado entre otros. (Sánchez-Páez y Álvarez-León, 1997, como se citó en CVC e INVEMAR, 2007).

Así, el distrito especial, industrial, portuario, biodiverso y ecoturístico de Buenaventura se encuentra ubicado en las coordenadas 3°53'25.98"N de latitud norte y 77°04'43.91"O de longitud oeste, a una altura de 7 m.s.n.m., situado dentro de la región del Chocó Biogeográfico el cual superpone una extensión de 50000 km², este municipio es el más extenso del departamento del Valle del Cauca, con un área de 6297 km². Para la zona de estudio (ver figura 1), específicamente la cuenca hidrográfica de Bahía de Buenaventura se obtuvo una capa vectorial del

geovisor de la Corporación Autónoma Regional del Valle del Cauca – CVC, el cual es una herramienta de consulta y análisis de datos cartográficos que se puede acceder a través del micrositio GeoCVC de la página web de esta entidad.




Figura 1: Zona de Estudio: Cuenca Hidrográfica Bahía de Buenaventura, Código CVC 53017000000

Fuente: Elaboración propia, 2022

6.2. Búsqueda, descarga y adquisición de material.

Para la obtención del material que permitió el desarrollo del proyecto se buscó y recopiló material bibliográfico de las diferentes entidades e instituciones que hacen presencia en la región, y/o han realizados estudios técnicos de la zona, tales como Universidad del Valle, CVC, INVEMAR, entre otras. Y, en cuanto al material para el desarrollo práctico se descargó imágenes de satélite del sensor TM y ETM (ver tabla 7), estas son de acceso libre y se obtienen a través del United States Geological

Survey (USGS) del año 2011. Cabe resaltar que las dos regiones útiles para analizar la vegetación son las regiones del rojo y del infrarrojo cercano por el comportamiento inverso de la respuesta de la energía que aporta en distinguir la vegetación y en cuanto a los manglares por estar asociado con el agua, así mismo, la región del infrarrojo de onda corta es de mucho interés puesto que el agua absorbe la energía y a mayor contenido de agua en la vegetación mayor absorción de energía (Rodríguez, 2018), por lo tanto, se utilizó imágenes de satélites cuyas bandas de onda corta tengan mejor resolución y tengan menor nubosidad. En consecuencia, se obtuvo una imagen Landsat del sensor TM y una imagen Landsat del sensor ETM + que presentan características definidas (ver tabla 8).

Tabla 7. Parámetros de las imágenes utilizadas.

Parámetros	Landsat 5	Landsat 7
ID	LT05_L1GS_010057_201103	LE07_L1GT_010057_20110304_
Producto	12_20161209_01_T2	20161210_01_T2
ID Sensor	TM	ETM
Path	10	10
Row	57	57
Proyección	UTM zona 18	UTM zona 18
Nubosidad	20%	36%
Fecha de adquisición	12 de marzo de 2011	04 de marzo de 2011

Fuente: Metadatos imágenes de satélite Landsat 5 y Landsat 7

Tabla 8. Características sensor TM y ETM.

Detalle	Sensor TM	Sensor ETM
Tipo de sensor	Opto-mecánico	Opto-mecánico
Resolución espacial	30 m (multiespectral)	30 m (multiespectral)
	120 m (térmica)	60 m (térmica)
		15 m (Pancromática)
Rango espectral	0,45 – 12,5 μm	0,45 – 12,5 μm
Número de bandas	7	8
Resolución temporal	16 días	16 días
Tamaño de la imagen	183 km X 170km	183 km X 170km

Fuente: NASA, 2019

Los materiales para el procesamiento de las imágenes de satélite lo conforman el software de acceso libre QGIS 3.20 el cual tiene previamente instalado el complemento Semi-Automatic Classification, las imágenes de satélite del sensor TM y ETM del año 2011 de la Bahía de Buenaventura.

7. METODOLOGÍA

Esta investigación propone aplicar una metodología para el mapeo de la concentración de manglar en la bahía de Buenaventura, a partir del procesamiento de imágenes satelitales del año 2011 apoyado en el complemento Semi-Automatic Classification Plugin en QGIS 3.20, (figura 2) el cual es un proceso rápido y práctico a través de un ejercicio tecnológico automatizado que permite obtener información de la cobertura de manglar y se evalúa con un proceso de validación a partir de la cartografía generada por García (2012).




Figura 2: *Flujograma Metodología*

7.1. Fase 1: Preprocesamiento de las imágenes satelitales

Para el diseño de la metodología del mapeo de concentración de manglar con imágenes satelitales Landsat fue necesario realizar un preprocesamiento de estas imágenes; esto con el fin de corregir las distorsiones atmosféricas, geométricas y radiométricas, puesto que las correcciones son indispensables pues posibilitan procesar las imágenes en tiempos y espacios diferentes, cabe mencionar que los manglares presentan diferentes respuestas espectrales según la época del año, debido a la influencia del agua, el suelo y la atmosfera, además de las diferencias

de fenómenos biológicos que dependen del clima y estructurales de la vegetación (Rodríguez et al., 2018).

Dado que la mejor imagen de satélite Landsat del sensor TM que se logró obtener contiene una nubosidad del 20% que afecta directamente la zona de estudio, se considera crear una imagen híbrida con otra imagen que conserven las mismas características, tal como es la imagen Landsat del sensor ETM, este proceso se realiza mediante la herramienta *r.patch* de GRASS GIS (ver figura 4). Sin embargo, esta imagen ETM presentan un bandeo (figura 3b), por lo que fue necesario en la corrección radiométrica se restituyera los píxeles perdidos a partir de la corrección de bandeo, esta corrección se hizo utilizando un filtro de mediana de una rutina del foro de Google Engine mediante el siguiente script:

```
var image_fill = clipl7.focal_mean(1, "square", "pixels", 10)
var image_fill3 = clipl7.focal_median(1, "circle", "pixels", 10)
var image_final = image_fill.blend(clipl7).clip(shape)
var image_final2 = image_fill3.blend(clipl7).clip(shape)
```

Para el enmascaramiento de las nubes de la imagen TM se tomó las bandas del rango espectral del visible para una reclasificación definiendo diferentes umbrales a partir de ensayo y error para determinar el adecuado, entre 0.8, 0.6 y 0.4 pudiendo obtener 0.6 como el mejor umbral.

7.2. Fase 2: Cálculo de índices espectrales

Anteriormente citado, las regiones del rojo y el infrarrojo cercano favorecen el análisis de la vegetación, debido a la presencia de un comportamiento opuesto a la respuesta de la energía, que ayuda a distinguir la vegetación; por el contenido de clorofila y otros componentes característicos de la vegetación, al igual que la estructura de las hojas, las cuales causan mayor absorción en el rojo, en consecuencia la reflectancia es baja además, es mayor la reflectancia en el NIR, aquí es importante, indicar que en los bosques de manglar, por estar ligados con el recurso hídrico, la región del SWIR presenta grandes ventajas ya que el agua absorbe la energía, y a mayor concentración de agua en la vegetación, se absorbe más la energía. (Sabins, 1996 y Chuvieco, 2008, como se citó en Rodríguez, 2018).

Para identificar las mejores combinaciones de bandas que comprueben la optimización del mejor compuesto que faciliten la detección de las características que conforman la cobertura de manglares se calculó el Optimun Index Factor (OIF) utilizando la ecuación (1) en el programa Microsoft Excel (ver tabla 11). Así mismo, se aplicó la técnica de conteo de combinación estadística sin repeticiones con el propósito de conocer el número de combinaciones posibles de bandas espectrales, definida en la ecuación (2).

A partir del OIF y con base en los tratadistas consultados entre ellos Rodríguez et al., (2018), señala que existen una gran variedad de índices para diversos fines, entre ellos se encuentran: Índice de vegetación normalizada (NDVI), índice de agua de diferencia normalizada (NDWI), índice modificado de agua de diferencia normalizada (MNDWI), sin embargo, para obtener mayor información de la respuesta espectral de la vegetación también se calculó los índices SAVI y el MVI.

7.3. Fase 3: Evaluación de métodos de clasificación para identificación de manglares

La clasificación de los manglares en la Bahía de Buenaventura se realizó mediante la técnica de clasificación supervisada, esta permite clasificar un conjunto de bandas utilizando las firmas espectrales marcadas en la lista de firmas y región de interés (ROI). Además, proporciona la implementación de algoritmos de distancia mínima, máxima probabilidad y mapeo de ángulos espectrales, por consiguiente, en el desarrollo de esta metodología se utilizan los tres algoritmos para experimentar su capacidad en esta zona de estudio. Es necesario resaltar que el algoritmo de máxima probabilidad es el más óptimo puesto que el principio de su funcionamiento está relacionado con los píxeles agrupados soportado en la propiedad de la probabilidad de una clase con un valor promedio y covarianza el cual es modelado en forma de una distribución normal (paramétrica) en un espacio de características multiespectrales. (Sisodia et al., 2014, como se citó en Purwanto y Riyanto, 2020)

7.4. Fase 4: Postprocesamiento de las imágenes

Debido a que las imágenes clasificadas en ocasiones presentan aspecto de sal y pimienta por la variabilidad espectral inseparable que se encuentran en una clasificación cuando se aplica píxel por píxel, en consecuencia, es necesario suavizar la imagen clasificada, y el filtro de mediana es óptimo puesto que reemplaza cada píxel central con el valor de la mediana del vecino más cercano según el tamaño del filtro (Castro y Donoho, 2009 como se citó en Dan et al., 2016). Entonces, se realizó la postclasificación aplicando el filtro de mediana contenido en el SCP que está dado por una matriz de 3x3 y es determinado por el número de umbral y el píxel de conexión que varía entre 4 y 8, este filtro está basado en el GDAL_sieve el cual reemplaza los valores de los píxeles dispersos por el valor del píxel del vecino más grande, generando una imagen mejorada.

7.5. Fase 5: Construcción de polígonos con concentración de manglar

Construcción de los polígonos de manglar de acuerdo con la mayor agrupación de píxeles homogéneos. Estos polígonos fueron validados usando una matriz de confusión y el índice Kappa que permitió conocer qué tan correcta es la clasificación realizada además del error obtenido en los productos generados, para ello se utilizó como mapa de referencia la cartografía realizada por García (2012).

8. RESULTADOS

8.1 Índices espectrales que contribuyen en la identificación de manglar en la bahía de Buenaventura.

Con las imágenes debidamente corregidas, además de la conversión a reflectancia de las imágenes Landsat 5 y Landsat 7, y la creación del ráster del conjunto de bandas través del SCP de QGIS, se realizó el recorte del ráster a partir de la capa vectorial de la cuenca de la Bahía de Buenaventura obtenida del GeoPortal de la CVC.




Figura 3: (a) Imagen 5 TM. Path 10 y Row 57, adquisición 12 de marzo de 2011;
(b) Imagen 7 ETM, Path 10 y Row 57, adquirida 04 de marzo de 2011

Fuente: USGS, 2021



Figura 4: Aplicación de parche en las imágenes Landsat de la zona de estudio

Fuente: propia, 2022

Aunque la imagen TM presenta una nubosidad de sólo el 20%, este moderado estado de nubosidad fue un obstáculo para la identificación de manglares, dado que abarca gran parte de la zona de estudio (Figura 3a), por lo tanto, se hizo el enmascaramiento de las nubes que cubrían esa zona y en composición con otra imagen de satélite Landsat del sensor ETM del mismo año, se logró obtener una imagen con menor nubosidad (figura 4). Este proceso se hizo a través de la caja de herramientas de procesamiento del programa GRASS GIS contenido en QGIS; dicha composición se construyó aplicando un parche mediante la herramienta *r.patch*, facilitando al usuario la creación de un ráster con la asignación de datos de

valores conocidos del ráster de entrada a las celdas de la respectiva región, (Shapiro, 2019). Para este ejercicio se llevó a cabo la superposición del ráster de entrada rellenando las celdas sin datos, por tanto, los huecos de la primera imagen, en este caso la Landsat 5 TM fueron rellenados con la imagen Landsat 7 ETM.

Con la imagen mejorada a partir de las correcciones, se determinó las bandas con mejor respuesta espectral, dicho proceso se realizó a través del Optimun Index Factor (OIF); para ello se requirió los datos estadísticos de las imágenes de satélites (tabla 9) y se calculó la matriz de correlación de las bandas 1, 2, 3, 4, 5 y 7 a través de la función *r.covar* del programa GRASS en QGIS (tabla 10). Aquí es importante subrayar que, antes de calcular el OIF, fue necesario saber cuántas combinaciones posibles se podrían realizar con las imágenes Landsat utilizadas en este proyecto, de modo que, se tuvo en cuenta que el uso significativo de los sensores remotos en la vegetación está soportado en los espectros de luz de la región visible, cuyo rango espectral están entre los 450 y 750 nm para el espectro visible y entre los 850 y 1700 nm para la banda infrarrojo cercano y medio (Jinru, et al., 2017).

Teniendo en cuenta que se requiere conocer el número de combinaciones posibles de las bandas espectrales para el estudio de la vegetación se aplicó la técnica de conteo de combinación estadística sin repeticiones (Ecuación 2).

Al calcular las combinaciones posibles cuyo valor de (n) es el número de bandas correspondiente a seis (6) y un tamaño de la muestra (r) equivalente a tres (3), se logró obtener 20 combinaciones posibles; seguidamente se calculó el OIF para cada combinación obteniendo como resultado que la mejor combinación es el compuesto de las bandas 1, 4 y 5 (ver tabla 11).

A causa de la identificación de las mejores combinaciones de bandas se determinó calcular índices de vegetación a la imagen híbrida mediante las bandas indicadas, así pues, se calculó el NDVI, el SAVI, el NDWI, el MNDWI, y el MVI permitiendo obtener el mejor índice y/o combinación para realizar la clasificación supervisada que posibilite detectar la concentración de bosques de manglar.

Tabla 9: Datos estadísticos de la imagen

Bandas	Mínimo	Máximo	Media	S_i
B1	0	65535	5563,63449	8807,0976
B2	0	27932	5341,09024	6132,4123
B3	0	28003	5133,8633	5944,9716
B4	0	31117	8051,3391	8760,5859
B5	0	24838	6071,80465	6702,2252
B7	0	21281	4877,21314	5390,4574

Tabla 10: Matriz de coeficientes de correlación

Bandas	B1	B2	B3	B4	B5	B7
B1	1	0,854414	0,859406	0,775400	0,809400	0,801566
B2	0,854414	1	0,999616	0,958899	0,986455	0,989803
B3	0,854414	0,999616	1	0,953410	0,983947	0,987996
B4	0,775400	0,958899	0,953410	1	0,987694	0,974739
B5	0,809400	0,986455	0,983947	0,987694	1	0,996135
B7	0,801566	0,989803	0,987996	0,974739	0,996135	1

Tabla 11. Valores del OIF

Clasificación	RGB	OIF	Clasificación	RGB	OIF
1	1-4-5	9434,38885	11	2-4-5	7362,72415
2	1-2-4	9155,16544	12	3-4-5	7318,77243
3	1-3-4	9084,50264	13	2-3-4	7156,0805
4	1-4-7	8997,17677	14	4-5-7	7048,43306
5	1-2-5	8165,86358	15	2-4-7	6938,21274
6	1-3-5	8087,55825	16	3-4-7	6891,2948
7	1-5-7	8016,48278	17	2-3-5	6323,06236
8	1-2-3	7696,69212	18	2-5-7	6131,45533
9	1-2-7	7683,91337	19	3-5-7	6077,21704
10	1-3-7	7603,91467	20	2-3-7	5866,78084

Fuente: propia, 2022

NDVI

La importancia del índice de vegetación normalizada en los estudios de vegetación determina el cálculo oportuno para detectar la vegetación de manglar en la zona de estudio, cuyo resultado es bueno, sin embargo, difícilmente se puede identificar con precisión el tipo de vegetación que cubre la cuenca.

La relación normalizada entre las bandas del rojo e infrarrojo están entre -1 y 0.469885. Esto comprueba la vigorosidad de la vegetación de la cuenca, ya que la mayor cantidad de píxeles están entre 0.32 y 0.36 y con menor frecuencia están los píxeles inferiores a cero, es decir, los que representan valores negativos indicando la ausencia de vegetación, estos píxeles estarían correspondiendo a cuerpos de agua, suelos desnudos, construcciones y/o asentamientos humanos, (figura 5).




Figura 5: Índice de vegetación normalizada (NDVI)

Fuente: propia, 2022

SAVI

La relación de los valores de reflectancia entre la vegetación y el fondo del suelo en la región del infrarrojo cercano y la región del rojo oscila entre -1.5 y 0.76. Teniendo en cuenta la vegetación de la zona de estudio, el cálculo del SAVI se realizó con la constante de compensación promedio $L = 0.5$ permitiendo mejorar el ajuste que principalmente es óptimo para densidades intermedias de vegetación. (Muñoz, 2013)




Figura 6: Índice de vegetación ajustado al suelo (SAVI)

Fuente: propia, 2022

Las características espectrales de la vegetación a partir del SAVI muestra una semejanza a la del NDVI, debido a que la ecuación tiene una relación normalizada entre las bandas del rojo e infrarrojo cercano que es ligeramente alterada por la constante L en el nominador, (Figura 6).

NDWI

La cantidad de agua que contiene la vegetación está entre -0.440739 y 1, este índice muestra que por su humedad es una zona óptima para el cultivo de manglares, de este índice se identifica que los píxeles en azul claro son construcciones artificiales y/o bosques secos y los píxeles azules en tonos oscuros corresponderían a cuerpos de agua y/o vegetación con un alto grado de humedad, sin embargo, el resultado de calcular el NDWI generó tonos muy claros en los cuerpos de agua (figura 7), por lo que es necesario calcular el MNDWI, el cual es un NDWI modificado, este contribuye en mejorar la precisión en los resultados.

MNDWI

Con el cálculo de este índice se aumenta la diferencia entre la reflectancia del agua y la vegetación de manglares, además de otros atributos como, edificaciones, suelos desnudos y otro tipo de vegetación; los valores están entre -0.401963 y 0.533287, los cuales corresponde a infraestructura para valores mínimo y nubes para los valores máximos. (Figura 8)




Figura 7: Índice diferencial de agua normalizado (NDWI)

Fuente: propia, 2022




Figura 8: Índice modificado de agua diferencial normalizado (MNDWI)

Fuente: propia, 2022

MVI

Con el cálculo del nuevo índice de vegetación de manglar propuesto por Baloloy et al., (2020) el cual relaciona las bandas verdes, NIR y SWIR1, muestra un valor mínimo de -0.0834 y un valor máximo de 6.14146, permitiendo identificar de manera clara los píxeles que corresponde a bosques de manglar, no obstante, por la alta nubosidad que presenta la bahía Buenaventura hay píxeles que tienden a mostrar una respuesta espectral semejante a los manglares (Figura 9).




Figura 9: Índice de vegetación de manglar (MVI)

Fuente: propia, 2022

Entre los índices de vegetación calculados, el MVI es el más indicado para realizar la clasificación supervisada, ya que visualmente presenta mejores características

espectrales para detectar la concentración de manglar, pudiendo percibir en colores verdes con tonalidad clara, no obstante, clasificar esta imagen generaría falsedad en los polígonos de bosques de manglares detectados, a causa de las sombras reflejadas por la nubosidad, estas presentan una semejanza espectral con los bosques de manglar (figura 12).

Así pues, se realizó otro tipo de combinaciones teniendo en cuenta el OIF el cual muestra las combinaciones con mayor información espectral (Figura 10), permitiendo obtener el compuesto de la banda 1, banda 4 y banda 5 las cuales se combinaron de manera que proporcionara la mejor alternativa a la clasificación, y se optó por la combinación RGB correspondiente a la banda 4, banda 5 y banda 1 respectivamente.




Figura 10: (a) Combinación 451, (b) Combinación 145, (c) Combinación 514, (d) Combinación 415, (e) Combinación 541 y (f) Combinación 154

8.2 Clasificación de las imágenes de satélite para el reconocimiento de zonas de manglares

Para clasificar las coberturas que incorporan la cuenca hidrográfica de Bahía de Buenaventura se utilizó los tres algoritmos de clasificación supervisada del SCP, inicialmente con la imagen obtenida al calcular el MVI siguiendo la metodología propuesta, para ello se tomaron suficientes áreas de entrenamiento generando la clasificación que muestra la figura 11, en ella se identifica la clase manglar como atributo incongruente con bosques de manglar en el terreno, esta incongruencia es proporcionada por píxeles de sombra que tiene una respuesta espectral semejante a los píxeles de manglar como se puede ver en la figura 12.




Figura 11: Imagen clasificada usando el MVI

Fuente: Construcción propia, 2022




Figura 12: Gráfico de firma espectral

Fuente: propia, 2022

Seguidamente se utilizó la imagen con las combinaciones de bandas 451, la cual se le aplicó el filtro de la mediana con un tamaño de 3x3 para suavizar la imagen y favorecer la diferenciación de píxeles proporcionando una mejor imagen. El filtro de la mediana es ideal porque no crea nuevos valores, y respeta los valores en píxeles de la imagen (figura 13).




Figura 13: Imagen filtrada

Fuente: propia, 2022




Figura 14: Áreas de entrenamiento

Fuente: propia, 2022

Con la imagen filtrada, mediante visualización se identificó las diferentes clases por consiguiente se tomó un número de muestra equivalente a 195 áreas de entrenamiento para las seis clases de coberturas identificadas en la imagen ráster de la zona de estudio, estas clases fueron determinadas con categorías de bosques mixtos, manglar, nubes, sombras, agua y tejido urbano procurando que tuviesen bien distribuidos y evitando confusión, esto permite no dejar píxeles sin entrenar para evitar puntos no clasificados que podrían ser de manglares y afectaría la precisión del ejercicio. Unas áreas de entrenamiento fueron construidas mediante polígonos otras por el algoritmo de región incremental el cual considera la semejanza espectral de los píxeles vecinos, esto se hizo con mucho cuidado evitando selección errónea (figura 14).

Primeramente, se realizó la clasificación supervisada aplicando el algoritmo de distancia mínima logrando obtener la imagen clasificada con muchos píxeles aislados del color de la clase asignada a manglares (figura15). Como se mencionó anteriormente, fue necesario aplicar un filtro que reemplazara estos píxeles y se usó el filtro de clasificación del SCP, el cual reemplaza los píxeles pequeños conforme al umbral proporcionado en este caso un umbral de 2 por el píxel vecino de mayor tamaño, también se tuvo en cuenta los píxeles conectados; inicialmente se hizo con una conexión de píxeles de 4, luego con una conexión de píxeles de 8, y finalmente se suavizó con un filtro de la mediana en una ventana de 7x7, generando un producto más limpio (figura 16).




Figura 15: Imagen clasificada, algoritmo mínima distancia

Fuente: Construcción propia, 2022




Figura 16: Imagen clasificada y mejorada, mínima distancia

Fuente: Construcción propia, 2022

En la segunda clasificación supervisada se realizó a través del algoritmo de máxima probabilidad (figura 17), así mismo que en el proceso de distancia mínima se le aplicó el filtro de clasificación del SCP basado en `gdal_sieve.py` con un umbral de 2 y conexión de píxeles equivalente a 8 y 4, teniendo en cuenta que el filtro de conexión de píxel 4 está definido en una ventana de 3x3, cuyos píxeles diagonales no se consideran conectados, y el de conexión de píxel de 8 es definido en una ventana de 3x3 con píxeles diagonales considerados conectados, además se suavizó la imagen con un filtro de mediana de 9x9 permitiendo limpiar un poco la imagen resultante y finalmente para cubrir huecos se usó un filtro de la moda de 3x3 de manera que usara el resultado del píxel que más se repite en el vecino más cercano (figura 18).




Figura 17: Imagen clasificada, algoritmo máxima probabilidad

Fuente: Construcción propia, 2022




Figura 18: Imagen clasificada y mejorada, máxima probabilidad
Fuente: Construcción propia, 2022

Por último, se hizo la clasificación usando el algoritmo de mapeo del ángulo espectral, este algoritmo por su capacidad según Congedo (2021) es muy usado con imágenes hiperespectrales. La clasificación generó un producto no muy preciso (figura 19), posterior a ello se aplicó el filtro del SCP con umbral y conexión de píxel 8 logrando eliminar algunos de los píxeles aislados, para mejorar la imagen se aplicó un filtro de la mediana de 3x3 que reemplazó otros píxeles dispersos y se logró obtener la imagen mejorada (figura 20).




Figura 19: Imagen clasificada, algoritmo mapeo de ángulo espectral
Fuente: Construcción propia, 2022




Figura 20: Imagen clasificada y mejorada, mapeo de ángulo espectral

Fuente: Construcción propia, 2022

8.3 Áreas con concentración de manglares, validación por matriz de confusión

Con el resultado de los mapas obtenidos adecuadamente mejorados por el proceso de filtrado, se realizó una reclasificación asignándoles nuevos valores de clase, así pues, se le fijó el valor 1 para áreas no manglar y el valor 2 para áreas con manglar, generando como resultado en la primera clasificación correspondiente al algoritmo de mínima distancia, áreas equivalentes a 1569.06 hectáreas de manglar y 31203.09 hectáreas de no manglar (figura 21); luego en la segunda clasificación con el algoritmo de máxima probabilidad, se obtuvo áreas equivalentes a 1905.03 has para manglar y 30760.56 has para no manglar (figura 22); por último en la tercera clasificación con el algoritmo de mapeo de ángulo espectral, se obtuvo un área de manglar de 1608.48 has y un área de no manglar de 31672.26 has (figura 23).

Los resultados de las áreas con concentración de manglar obtenidas por los tres algoritmos han sido diferentes, debido al comportamiento del algoritmo, dado que el algoritmo por distancia mínima se encarga de identificar la clases más cercana, es decir, a los píxeles de la imagen se le atribuye una clase con distancia mínima, el algoritmo de máxima probabilidad exige un número alto de píxeles para la matriz de covarianza que es precisa para determinar la similitud entre los píxeles, y el mapeo de ángulo espectral relaciona la pertenencia de la clase por el ángulo menor del píxel, por tanto, para este último algoritmo es mejor si la resolución espacial es mínima. Ahora bien, la resolución espacial de las imágenes procesadas es mediana, lo cual puede generar confiabilidad, sin embargo, para este tamaño de resolución

espacial es necesario realizar una validación preferiblemente en campo como señala Rodríguez (2018).




Figura 21: Concentración de manglar con algoritmo de mínima distancia, realizado a imagen híbrida TM y ETM, Path 10 Row 57 de marzo de 2011

Fuente: Construcción propia, 2022




Figura 22: Concentración de manglar con algoritmo de máxima probabilidad, realizado a imagen híbrida TM y ETM, Path 10 Row 57 de marzo de 2011

Fuente: Construcción propia, 2022




Figura 23: Concentración de manglar con algoritmo de mapeo de ángulo espectral, realizado a imagen híbrida TM y ETM, Path 10 Row 57 de marzo de 2011

Fuente: Construcción propia, 2022

Con los polígonos obtenidos es necesario calcular su nivel de confianza midiendo la exactitud de las clasificaciones realizadas y así obtener los errores de los mapas, por tanto, se empleó la matriz de confusión propuesta.

Esta matriz de confusión igualmente se realizó con el SCP la cual calcula el error basado en el píxel y el error basado en el área, en el que cada valor representa la correlación del área estimada de cada clase, permitiendo evaluar la precisión del usuario y la del productor (Congedo, 2021).

Tabla 12. Evaluación de la exactitud polígonos, mínima distancia

Código	Matrix de Error	Referencia	Clasificada	Suma de Píxel
1		1	1	332066
3		1	2	6601
2		2	1	9908
4		2	2	11830

Clasificada	Matriz de Error (Píxel)		
	Referencia		
	1 (No Manglar)	2 (Manglar)	Total
1 (No Manglar)	332066	9908	341974
2 (Manglar)	6601	11830	18431
Total	338667	21738	360405

Matriz de Error (Área)				
Referencia				
Clasificada	1 (No Manglar)	2 (Manglar)	Área (m2)	Wi
1 (No Manglar)	0,9215	0,0275	310968900	0,949
2 (Manglar)	0,0183	0,0327	16698600	0,051
Total	0,9398	0,0602	327667500	
Área	307939756	19727744		
Desviación Estándar	0,0003	0,0003		
Intervalo de Confianza Área (95%)	209578	209578		
Exactitud Productor (%)	98,0579	54,3298		
Exactitud Usuario (%)	97,1027	64,1853		
Kappa hat	0,5188	0,6189		
Precisión Total (%)		95,4252		
Clasificación Kappa		0,5644		

Tabla 13. Evaluación de la exactitud polígonos, máxima probabilidad

Código	Referencia	Clasificada	Suma de Píxel
1	1	1	331156
3	1	2	7688
2	2	1	8282
4	2	2	13369

Matriz de Error (Píxel)			
Referencia			
Clasificada	1 (No Manglar)	2 (Manglar)	Total
1 (No Manglar)	331156	8282	339438
2 (Manglar)	7688	13369	21057
Total	338844	21651	360495

Matriz de Error (Área)				
Referencia				
Clasificada	1 (No Manglar)	2 (Manglar)	Área (m2)	Wi
1 (No Manglar)	0,9187	0,023	307605600	0,9417
2 (Manglar)	0,0213	0,037	19050300	0,0583
Total	0,94	0,06	326655900	
Área	307055629	19600271		
Desviación Estándar	0,0003	0,0003		
Desviación Estándar área	103106	103106		
Intervalo de Confianza Área (95%)	202087	202087		
Exactitud Productor (%)	97,7348	61,7081		
Exactitud Usuario (%)	97,5601	63,4896		
Kappa hat	0,5934	0,6116		

Precisión Total (%)	95,5731
Clasificación Kappa	0,6023

Tabla 14. Evaluación de la exactitud polígonos, mapeo ángulo espectral

Código Matrix de Error	Referencia	Clasificada	Suma de Píxel
1	1	1	333214
3	1	2	6052
2	2	1	10066
4	2	2	11616

Matriz de Error (Píxel)			
Referencia			
Clasificada	1 (No Manglar)	2 (Manglar)	Total
1 (No Manglar)	333214	10066	343280
2 (Manglar)	6052	11616	17668
Total	339266	21682	360948

Matriz de Error (Área)				
Referencia				
Clasificada	1 (No Manglar)	2 (Manglar)	Área (m2)	Wi
1 (No Manglar)	0,9227	0,0279	311274900	0,9506
2 (Manglar)	0,0169	0,0325	16196400	0,0494
Total	0,9396	0,0604	327471300	
Área	307695303	19775997		
Desviación Estándar	0,0003	0,0003		
Desviación Estándar Área	106667	106667		
Intervalo de Confianza Área (95%)	209067	209067		
Exactitud Productor (%)	98,1969	53,8455		
Exactitud Usuario (%)	97,0677	65,746		
Kappa hat	0,5144	0,6354		

Precisión Total (%)	95,5186
Clasificación Kappa	0,5686




Figura 24: Precisión total clasificación

Fuente: Construcción propia, 2022




Figura 25: Concordancia clasificación
Fuente: Construcción propia, 2022

La matriz de confusión validó los mapas obtenidos por la clasificación supervisada aplicando el algoritmo de mínima distancia en el que se obtuvo un nivel de confianza de 95.4%, para el algoritmo de máxima probabilidad su nivel de confianza fue de 95.57 y para el algoritmo de mapeo de ángulo espectral su nivel de confianza fue de 95.51.

En cuanto al índice Kappa, muestra que hay una concordancia por encima del azar, puesto que los valores representados por cada uno de los resultados son de 0.56 para mínima distancia, 0.60 para máxima probabilidad y 0.56 para mapeo de ángulo espectral. Estos valores al relacionarlos con la escala de valoración (tabla 5) definida por Landis y Koch (1977) es moderada para el mapa clasificado por los algoritmos de mínima distancia y mapeo de ángulo espectral, y considerable para la clasificación por el algoritmo de máxima probabilidad.

9. CONCLUSIONES

Finalmente, se logró el diseño de una metodología basado en el plugin Semi-Auto classification SCP para QGIS en el mapeo de la concentración de manglar de la bahía de Buenaventura en el Valle del Cauca, el cual permitió evaluar índices espectrales fijados en las regiones del visible e infrarrojo que, si bien pudieron ser fundamental para la clasificación supervisada, las variables atmosféricas afectaron considerablemente el uso ideal de estos índices. No obstante, el uso del OIF para calcular la mejor combinación del compuesto de bandas espectrales fue oportuno

para lograr el objetivo, además del uso de las técnicas estadísticas como los filtros que mejoran la visualización de las imágenes.

Por la complejidad que presenta mapear un tipo de cobertura boscosa como los manglares en la zona de estudio fue necesario ser muy minucioso en la escogencia de las áreas de entrenamiento que conllevó a crear 195 áreas de interés de seis clases de coberturas identificadas, lo cual favoreció en la precisión de la clasificación supervisada.

La evaluación de la fortaleza de la clasificación supervisada usando los tres algoritmos implícitos en el SCP demostró su capacidad de operar datos sistemáticamente generando resultados confiables como lo aprobó la herramienta estadística de matriz de confusión y lo comprobó el índice Kappa mediante la evaluación de la concordancia entre lo observado y lo esperado.

Con el cálculo de la matriz de confusión se valida que los mapas generados presentan una exactitud global de más del 95%, por tanto, el resultado obtenido del mapeo de la concentración de manglares es confiable, es decir, hay una relación fiable entre los polígonos clasificados y el mapa de validación.

La clasificación por el algoritmo de máxima probabilidad presenta mayor concordancia que las realizadas por los algoritmos de mínima distancia y mapeo de ángulo espectral, lo que podría relacionarse con su rigurosidad del comportamiento del algoritmo soportado en la covarianza.

La metodología diseñada es apropiada para etapas de exploración, seguimiento o monitoreo rápido de manglar que permita evidenciar los cambios de bosques en áreas grandes y representativas.

Para terminar, se relaciona el resultado obtenido en la clasificación mediante el algoritmo de máxima probabilidad cuya área de bosques de manglar es equivalente a 1905.03 has con los resultados obtenidos por la CVC en el año 2001 y por García en el año 2012, los cuales corresponden a un área en hectáreas de 1910.4 y 1984.5 respectivamente, por tanto, la técnica se aproxima a resultados de escala 1:100000 del levantamiento realizado en el año 2001; y en la comparación con el levantamiento realizado en el año 2012, se identifica que en este se aplicó una técnica de restauración de píxel de 30 metros a 10 metros de resolución espacial proporcionando optimizar el insumo para una escala más detallada, teniendo en cuenta que la nubosidad y las sombras son un factor que afecta los levantamientos de bosques de manglar a partir de procesamiento digital de imágenes de satélite, incluso, afectó la detección de los manglares en los bordes de los ríos.

10. RECOMENDACIONES

Se recomienda aplicar esta metodología preferiblemente en zonas con baja nubosidad de manera que permita generar resultados mejorados y evitar un trabajo más laborioso, además de la pérdida de información de coberturas de bosques de manglar en el proceso de clasificación, ya que al trabajar en zonas con condiciones atmosféricas desfavorables a partir de imágenes satelitales ópticas, puede ocurrir una cierta cantidad de errores en la clasificación de estas coberturas; esto se puede presentar por las similitudes espectrales de otras clases de coberturas como sombras o nubes. También es necesario tener en cuenta el uso de imágenes de satélite con una resolución espacial óptima para poder detectar con mayor precisión las coberturas de manglares, por consiguiente, existen diferentes imágenes tales como Rapid Eye que tiene una resolución espacial de 5 metros y se puede adquirir de forma gratuita en el geoportal de la CVC; imágenes Sentinel las cuales tienen una resolución espacial de 10 metros y se pueden descargar de forma gratuita utilizando el SCP desde la página web del centro de acceso abierto de Copernicus; imágenes Planet Scope con resolución de 3 metros de resolución espacial de libre acceso a través del portal de datos abiertos del Instituto Geográfico Agustín Codazzi IGAC.

11. REFERENCIAS BIBLIOGRÁFICAS

- Aguilar Arias, Heileen, & Mora Zamora, Rodolfo, & Vargas Bolaños, Christian (2014). *Metodología para la corrección atmosférica de imágenes aster, rapideye, spot 2 y Landsat 8 con el módulo flash del software ENVI*. Revista Geográfica de América Central, 2(53),39-59. [fecha de Consulta 4 de octubre de 2021]. ISSN: 1011-484X. Recuperado de: <https://www.redalyc.org/articulo.oa?id=451744544002>
- Baloloy, A. B., Blanco, A. C., Sta. Ana, C. R., Nadaoka, K., (2020). *Development and application of a new mangrove vegetation index (MVI) for rapid and accurate mangrove mapping*, ISPRS Journal of Photogrammetry and Remote Sensing, Volume 166, Pages 95-117, ISSN 0924-2716. Recuperado de: <https://doi.org/10.1016/j.isprsjprs.2020.06.001>.
- Boca, T. & Rodríguez, G. (2012) *Métodos estadísticos de la evaluación de la exactitud de productos derivados de sensores remotos*. Asociación Argentina de Mecánica Computacional. Buenos Aires (Argentina): Instituto Nacional de Tecnología Agropecuaria. Recuperado de: https://inta.gob.ar/sites/default/files/script-tmp-inta-_mtodos_est__sensores.pdf
- Ceccato, P., Flasse, S., Tarantola, S., Jacquemond, S., and Gregoire, J.M. (2001). *Detecting vegetation water content using reflectance in the optical domain*. Remote Sensing of Environment 77: 22–33. ISSN 0034-4257. Recuperado de: [https://doi.org/10.1016/S0034-4257\(01\)00191-2](https://doi.org/10.1016/S0034-4257(01)00191-2).
- Congedo, Luca, (2021). Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. Journal of Open Source Software, 6(64), 3172. Recuperado de <https://doi.org/10.21105/joss.03172>
- Corporación Autónoma Regional del Valle del Cauca, CVC, (2020). *Plan de Acción 2020 – 2023, Mas cerca de la gente*. Santiago de Cali. Dirección de Planeación. Recuperado de: <https://www.cvc.gov.co/documentos/planes-y-programas/planes-de-accion-cuatrienal/plan-de-accion-2020-2023>
- Chuvieco, E. 2008. *Teledeteccion ambiental. La observación de la Tierra desde el espacio*. Ariel, Barcelona. Recuperado de: <https://docer.com.ar/doc/ensnxv5>
- Dan, T. T., Chen, C. F., Chiang, S. H., & Ogawa, S. (2016). MAPPING AND CHANGE ANALYSIS IN MANGROVE FOREST BY USING LANDSAT IMAGERY. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, 3(8). Recuperado de:

<https://pdfs.semanticscholar.org/9d88/af7bfdc3c0f5f8bca0c561258d033b2505d7.pdf>

- Flores, C. F., Aragón, N. A. & Manzano, S. M., (2011). *Evaluación del estado de salud de la vegetación de manglar en el sistema lagunar Santa María – La Reforma, Sinaloa, a partir de imágenes Landsat TM 5*. XIX Reunión Nacional SELPER – México. Recuperado de: https://www.ciga.unam.mx/publicaciones/images/abook_file/MemoriasSelper2011.pdf
- Food and Agriculture Organization, FAO, 2007. *The World's Mangroves 1980–2005*; FAO Forestry Paper 153; Food and Agriculture Organization of the United Nations: Rome, Italy. Recuperado de: <http://www.fao.org/3/a1427e/a1427e.pdf>
- García, C. E., (2012). *Informe final prestación de servicios profesionales para apoyar la gestión del grupo biodiversidad en la generación de cartografía temática de cobertura de manglar para el departamento del valle del cauca, mediante el procesamiento digital de imágenes landsat del 2011*. Memoria técnica, CVC. Cali.
- González, C., Sebem, E., García, R., de la Vega, R., Valverde, A., (2003) *Aportaciones de los GIS a la mejora de las clasificaciones temáticas mediante técnicas de clasificación experta*. Teledetección y Desarrollo Regional. X Congreso de Teledetección. Cáceres, España, 2003. pp. 201-204. Recuperado de: <http://www.aet.org.es/congresos/x/cac47.pdf>
- Heenkenda, Muditha K., Joyce, Karen E., Maier, Stefan W and Bartolo, Renee. (2014). *Mangrove Species Identification: Comparing WorldView-2 with Aerial Photographs*. Recuperado de: <https://doi.org/10.3390/rs6076064>
- Hernández, C., G. (2019). *Manual de prácticas de laboratorio para el procesamiento de imágenes satelitales*. UNAM. Recuperado de: <http://www.ptolomeo.unam.mx:8080/xmlui/>
- Hernández-Ramos, Jonathan, García-Cuevas, Xavier, Pérez-Miranda, Ramiro, González-Hernández, Antonio, & Martínez-Ángel, Luis. (2020). *Inventario y mapeo de variables forestales mediante sensores remotos en el estado de Quintana Roo, México*. Madera y bosques, 26(1), e2611884. Epub 30 de junio de 2020. Recuperado de: <https://doi.org/10.21829/myb.2020.2611884>
- IDEAM, IGAC y CORMAGDALENA, (2008). *Mapa de Cobertura de la Tierra Cuenca Magdalena-Cauca: Metodología CORINE Land Cover adaptada para Colombia a escala 1:100.000*. Instituto de Hidrología, Meteorología y Estudios Ambientales, Instituto Geográfico Agustín Codazzi y Corporación

Autónoma Regional del río Grande de La Magdalena. Bogotá, D.C., 200p. + 164 hojas cartográficas.

IDEAM, (2015). *Tomo II: Deforestación y afectación de los ecosistemas por ocupación del territorio y actividades económicas*. Bogotá, D. C., 385 páginas. Recuperado de: http://documentacion.ideam.gov.co/openbiblio/bvirtual/023437/Informe_Tomo2.pdf

INVEMAR Y CVC, (2007). *Monitoreo de los manglares del Valle del Cauca y la fauna asociada con énfasis en las aves y especies de importancia económica como la piangua y el cangrejo azul*. Informe Técnico Final. Buenaventura – Colombia. Recuperado de: http://cpps.dyndns.info/cpps-docs-web/planaccion/biblioteca/pordinario/Proceso%20Ordinario/Mangroves%2C%20salt%20marsh%20and%20other%20macro-vegetation%20areas/Informe%20CVC%20Manglares_2007.pdf

Jinru Xue, Baofeng Su, "Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications", *Journal of Sensors*, vol. 2017, Article ID 1353691, 17 pages, 2017. Recuperado de: <https://doi.org/10.1155/2017/1353691>

Kuenzer, Claudia, Andrea Bluemel, Steffen Gebhardt, Tuan Vo Quoc, and Stefan Dech. 2011. *Remote Sensing of Mangrove Ecosystems: A Review* Remote Sensing 3, no. 5: 878-928. <https://doi.org/10.3390/rs3050878>

Landis, J. R., & Koch, G. G. (1977). The Measurement of Observer Agreement for Categorical Data. *Biometrics*, 33(1), 159–174. Recuperado de: <https://doi.org/10.2307/2529310>

Moncayo Silva, P. J. (2017). *Estimación desde satélites de la fracción de área inundada en humedades fluviales de un sector de la planicie de inundación del Bajo Paraná, Argentina* (Master's thesis). Recuperado de: <http://hdl.handle.net/11086/5818>

Muñoz Aguayo, Pedro. Centro de Información de Recursos Naturales (Chile). 2013-04. Apuntes de teledetección: índices de vegetación. CIREN. Recuperado de <http://bibliotecadigital.ciren.cl/handle/20.500.13082/26389>

NASA, (2019). *Landsat 7 Science Data User's Handbook*. Recuperado de: <https://www.usgs.gov/landsat-missions/landsat-7-data-users-handbook>

NASA, (2008). *Landsat Missions, Landsat 7*. Recuperado de: <https://www.usgs.gov/landsat-missions/landsat-7>

- NASA, (2015). Landsat Science. Satellites. Recuperado de: <https://landsat.gsfc.nasa.gov/>
- QGIS (2020). *QGIS Un Sistema de Información Geográfica libre y de Código Abierto*. Recuperado de: <https://docs.qgis.org> .
- Patel, N., Kaushal, B. *Classification of features selected through Optimum Index Factor (OIF) for improving classification accuracy*. Journal of Forestry Research **22**, 99–105 (2011). Recuperado de: <https://doi-org.bd.univalle.edu.co/10.1007/s11676-011-0133-4>
- Purwanto, Anang Dwi; Ardli, Erwin Riyanto. *Development of A Simple Method for Detecting Mangrove Using Free Open Source Software*. Jurnal Segara, [S.l.], v. 16, n. 2, p. 71-82, june 2020. ISSN 2461-1166. Recuperado de: <http://ejournal-balitbang.kkp.go.id/index.php/segara/article/view/7512>>. Date accessed: 20 nov. 2021. doi:<http://dx.doi.org/10.15578/segara.v16i2.7512>.
- República de Colombia, Ministerio de Ambiente y Desarrollo Sostenible (2017). *Resolución 0706 de 2017*. Bogotá D. C. Recuperado de: <https://www.minambiente.gov.co/images/normativa/app/autos/res%20706%20de%202017-3c.pdf>
- República de Colombia, Ministerio de Ambiente y Desarrollo Sostenible *Resolución 1602 de 1995*. Bogotá. Recuperado de: https://www.minambiente.gov.co/images/BosquesBiodiversidadyServiciosEcosistemicos/pdf/Manglares/res_0020_090196.pdf
- Restrepo, J., Vivas-Aguas, L. J. 2007. *Manual metodológico sobre el monitoreo de los manglares del Valle del Cauca y fauna asociada, con énfasis en aves y especies de importancia económica: piangua y cangrejo azul*. Instituto de Investigaciones Marinas y Costeras - INVEMAR - Santa Marta. 40 p. Recuperado de: http://www.invemar.org.co/redcostera1/invemar/docs/8875Manual_Manglares_pacifico.pdf
- Riaño, M. O., Acosta, C. D. & Leal, R. O. (2016). *Clasificación de una imagen satelital empleando máquinas de soporte vectorial para cuantificar el área de Pinus Patula en una plantación*. Volumen especial. Pags 145. Universidad Distrital Francisco José de Caldas. Bogotá. Recuperado de: <https://revistas.udistrital.edu.co/index.php/REDES/article/view/11991/12620>

- Richards, J. A. and Jia, X., (2006). *Remote Sensing Digital Image Analysis: An Introduction*. Berlin, Germany: Springer. Recuperado de: <https://doi-org.bd.univalle.edu.co/10.1007/3-540-29711-1>
- Rodríguez Zúñiga M. T., E. Villeda Chávez, A. D. Vázquez-Lule, M. Bejarano, M. I. Cruz López, M. Olguín, S. A. Villela Gaytán, R. Flores (Coordinadores). (2018). *Métodos para la caracterización de los manglares mexicanos: un enfoque espacial multiescala*. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. Ciudad de México. 272 pp.
- Roy, S., Mahapatra, M. & Chakraborty, A. *Mapping and monitoring of mangrove along the Odisha coast based on remote sensing and GIS techniques*. *Model. Earth Syst. Environ.* **5**, 217–226 (2019). Recuperado de: <https://doi-org.bd.univalle.edu.co/10.1007/s40808-018-0529-7>
- Shimu, S. A., Aktar, M., Afjal, M. I., Nitu, A. M., Uddin M. P. and Al Mamun M., "NDVI Based Change Detection in Sundarban Mangrove Forest Using Remote Sensing Data," 2019 4th International Conference on Electrical Information and Communication Technology (EICT), 2019, pp. 1-5. Obtenido de doi: 10.1109/EICT48899.2019.9068819.
- Sarmiento, Benjamín; Fernández, Felipe (2014). *Combinatoria para la escuela*. En Andrade, Luisa (Ed.), *Memorias del I Encuentro Colombiano de Educación Estocástica* (pp. 140-146). Bogotá: Asociación Colombiana de Educación Estocástica. Recuperado de: <http://funes.uniandes.edu.co/6544/1/Sarmiento2014CombinatoriaECEE.pdf>
- Secretaría de la Convención de Ramsar, (2010). *Inventario de humedales: Marco de Ramsar para el inventario y la descripción de las características ecológicas de los humedales*. Manuales Ramsar para el uso racional de los humedales, 4ª edición, vol. 15. Secretaría de la Convención de Ramsar, Gland (Suiza). Recuperado de: <https://www.ramsar.org/sites/default/files/documents/pdf/lib/hbk4-15sp.pdf>
- Shapiro, Michael, (2019). *GRASS r.patch*. GRASS GIS 7.4.5. Recuperado de: <https://grass.osgeo.org/grass74/manuals/r.patch.html>
- Unidad de Planeación Minero Energética, UPME (2018). *Análisis área de estudio preliminar y alertas tempranas*. Ministerio de Minas. Bogotá. Recuperado de: <https://www1.upme.gov.co/>
- USGS (2019). *Manual para usuarios de datos de Landsat 8*. Versión 5. Recuperado de: <https://www.usgs.gov/media/files/landsat-8-data-users-handbook>

Vásquez Prieto, L. P. (2019). *Diseño de una metodología de clasificación de cobertura de manglar empleando imágenes SAR polarimétricas*. Universidad Católica de Manizales. Recuperado de:
<http://hdl.handle.net/10839/2511>